T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ VE VERİ BİLİMİ İLE GÜRÜLTÜ, TİTREŞİM VE SERTLİK ANALİZİNİN GELİŞTİRİLMESİ

Kemal DEMİR

YÜKSEK LİSANS TEZİ

Makine Mühendisliği Anabilim Dalı

Makine Teorisi ve Kontrol Programı

Danışman

Prof. Dr. Cihan DEMİR

Temmuz, 2025

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ VE VERİ BİLİMİ İLE GÜRÜLTÜ, TİTREŞİM VE SERTLİK ANALİZİNİN GELİŞTİRİLMESİ

Kemal DEMİR tarafından hazırlanan tez çalışması 03.07.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı, Makine Teorisi ve Kontrol Programı **YÜKSEK LİSANS** olarak kabul edilmiştir.

Prof. Dr. Cihan DEMİR
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. CİHAN DEMİR, Danışman
Yıldız Teknik Üniversitesi _____

Doç. Dr. MERAL BAYRAKTAR, Üye
Yıldız Teknik Üniversitesi _____

Doç. Dr. OSMAN TAHA ŞEN, Üye
İstanbul Teknik Üniversitesi _____

Danışmanım Prof. Dr. Cihan Demir sorumluluğunda tarafımca hazırlanan “Makine Öğrenimi Ve Veri Bilimi İle Gürültü, Titreşim Ve Sertlik Analizinin Geliştirilmesi” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Kemal DEMİR

İmza

Eşime, oğluma

ve

aileme

TEŞEKKÜR

Bu tezin hazırlanmasında emeği geçen herkese içten teşekkürlerimi sunarım. Öncelikle, bu çalışmanın temelini oluşturan veri setini sağlayan ve araştırmamın her aşamasında destek olan ANADOLU ISUZU Test Ekibine teşekkür ederim. Büyük veri analizine yönelik bilgilerimi derinleştirmemde ve araştırma sürecinde karşılaştığım zorlukları aşmamda bana rehberlik eden danışmanım Prof. Dr. Cihan Demir 'e özel teşekkürlerimi iletiyorum. Bilgi ve deneyimleri, bu tezin şekillenmesinde büyük bir etkiye sahip olmuştur.

Ayrıca, eşime ve arkadaşlarıma, bu süreçteki sürekli destekleri ve cesaretlendirmeleri için minnettarım. Bu süreçte motivasyon kaynağım oldular.

Son olarak, bu çalışmanın araç tasarımı ve mühendislik uygulamaları alanında önemli bir katkı sağlamasını umuyorum. Araştırmamın sonuçlarının, gürültü, titreşim ve sertlik seviyelerinin yönetimi konusunda yeni yaklaşımlar geliştirilmesine yardımcı olacağına inanıyorum.

Adı SOYADI

KEMAL DEMİR

İÇİNDEKİLER

TEŞEKKÜR iv
SİMGE LİSTESİ vii
KISALTMA LİSTESİ ix
ŞEKİL LİSTESİ x
TABLO LİSTESİ xi
ÖZET xii
ABSTRACT 15
1 GİRİŞ 18
1.1 Literatür Özeti 18
1.2 Tezin Amacı 18
1.3 Hipotez 21
2 ARAÇ GÜRÜLTÜ TİTREŞİMİ VE MAKİNE ÖĞRENİMİ TEMELLERİ 22
2.1 Araç Gürültü ve Titreşim Temelleri 22
2.1.1 Yapısal ve Hava Kaynaklı Gürültü 24
2.1.2 Araçlarda Gürültü Kaynakları ve İletim Yolu 24
2.1.2.1 Güç Aktarma Sistemlerinin Gürültü ve Titreşimleri 25
2.1.2.2 Hava Emiş Sistemi Gürültüsü 26
2.1.2.3 Egzoz Sistemi Gürültüsü 28
2.1.2.4 Motordan Yayılan Gürültü 29
2.2 TPA ve ODS Testlerinin Temelleri 33
2.2.1 Transfer Patika Analizi (TPA) 33
2.2.2 Operasyonel Sapma Şekli (ODS) 35
2.3 Ön Veri İşlemenin Temelleri 37
2.3.1 Veri Temizleme 38
2.3.2 Veri Dönüşümü 38
2.3.3 Aykırı Değerlerin Belirlenmesi ve İşlenmesi 39
2.3.4 Filtreleme 40

2.3.5 Gürültü Azaltma 41
2.3.6 Veri Özelliklerinin Çıkartılması 41
2.4 Makine Öğrenimi Temelleri 41
2.4.1 GTS Problemlerinde Rastgele Orman Algoritmasının Matematiksel Avantajları 43
2.4.2 Modelleme Yaklaşımı 45
3 GÜRÜLTÜ TİTREŞİM TESTLERİ VE METOD 48
3.1 Test Metodunun Seçimi 49
3.2 Test Ortamı 50
Şekil 3.1 Araç yol testleri 50
3.3 Veri Toplama Donanım ve Yazılımı 51
4 GÜRÜLTÜ TİTREŞİM TESTLERİ VE VERİ TAHMİN METODU 54
4.1 Sürüş Testi Verilerinin İncelenmesi 55
4.2 Frekans Temelli Filtreleme Yaklaşımı 61
4.3 Keşifsel Veri Analizi 63
4.4 Makine Öğrenimi Kullanarak Değişken Önem Analizi 68
4.5 Korelasyon Analizi 77
4.6 Hassasiyet Analizi 81
5 TEKNİK İSTATİSTİKLER KULLANILARAK GELİŞTİRME HEDEFLERİNİN SEÇİMİ 83
5.1 Analiz Yöntemi 83
5.2 Geliştirme Hedefleri 85
5.3 Gürültü Azaltımı İçin Çözüm Önerileri 86
6 SONUÇ 87
6.1 Veri Temizliği ve Aşırı Öğrenme Kontrolü 87
6.2 Yeni Veri Analizi Yönteminin Güvenilirliği 89
6.3 Klasik Yöntemlere Göre Sağlanan Kazanımlar 90
6.4 Gelecek Çalışmalar ve Potansiyel Genişleme 90
6.5 Sonuçların Endüstriyel Uygulaması 91
6.5.2 Fabrika İçi Üretim Süreçlerine Entegrasyon 91
KAYNAKÇA 93

SİMGE LİSTESİ

f_n	Dönme frekansı
s	Sıra sayısıdır
RPM	Dönen bileşenin dakikadaki devridir
GTF_{ik}	Yapısal kaynaklı gürültü transfer fonksiyonu
F_i	Yapısal kaynaklı titreşim kuvvetleri
GTF_{jk}	Hava kaynaklı gürültü transfer fonksiyonu
Q_j	Hava kaynaklı ait akustik yükler (ses debileri)
$X(\omega)$	Frekans domaininde yer değiştirme (ODS)
$F(\omega)$	Dış kuvvetlerin frekans domainindeki etkisi
ω	Frekans
M, K, C	Kütle, sertlik ve sönüm matrisleri
$X_{\text{çıktı}}$	Çıkış noktasındaki yer değiştirme
F_{girdi}	Giriş noktasındaki kuvvet
x_i	Veri setindeki veriler
μ	Verilerin ortalaması
σ	Verilerin standart sapma
Q_1	1.çeyrek
Q_3	3.çeyrek
N	Veri setindeki öğe sayısı,
x_i	Her bir veri noktası,
μ	Veri setinin ortalamasıdır.
y	Hedef değişken
x_i	Sensörlerden gelen giriş değişkenleri
T	Toplam karar ağacı sayısı

h_t	Her bir karar ağacının tahmini (örneğin regresyon ağacı)
$\hat{f}(x)$	Nihai tahmin sonucu (örneğin, iç mekân gürültüsü)
R_{tj}	Karar ağacının j. bölgesi
cc_{tj}	O bölgedeki ortalama tahmin değeri
I	Gösterim fonksiyonu (örnek x, bölgeye düşüyorsa 1, yoksa 0)
n	Gözlem sayısı (veri noktalarının sayısı)
y_i	Gerçek gözlem değeri (i'inci veri noktasının gerçek değeri)
$\hat{y}_i$	i'inci veri noktasının tahmin edilen değeri)
ρ	Pearson katsayısı
x_i	X değişkenine ait i'nci gözlem değeri
y_i	Y değişkenine ait i'nci gözlem değeri
$\bar{x}$	X değişkeninin ortalaması
$\bar{y}$	Y değişkeninin ortalaması

KISALTMA LİSTESİ

GTS	Gürültü, titreşim, sertlik
TPA	Transfer patika analizi
HFD	Hızlı fourier dönüşümü
KVA	Keşifsel veri analizi
GTF	Gürültü transfer fonksiyonu
FTF	Frekans tepki fonksiyonu
ODS	Operasyonel deplasman şekli
OYF	Olasılık Yoğunluk Fonksiyonu
KDF	Kümülatif Dağılım Fonksiyonu
ÇAA	Çeyrekler arası aralık
TBA	Temel bileşen analizi
RF	Random forests
HTF	Hareket transfer Fonksiyonu
KOKH	Kök ortalama kare hatası
OKH	Ortalama kare hatası
OMH	Ortalama mutlak hata
I4	4 silindirli sıralı motorlar
I6/V6	6 silindirli sıralı veya V düzenindeki motorlar
V8	8 silindirli V motorlar
OYF	Olasılık yoğunluk fonksiyonu
OKH	Ortalama karekök hatası

ŞEKİL LİSTESİ

Şekil 2.1 Araç gürültü ve titreşim kaynakları 26
Şekil 2.2 Hava emiş ve egzoz sistemi bileşenleri 27
Şekil 2.3 Yapı kaynaklı ve hava kaynaklı motor gürültüsü yayılımı……..….30
Şekil 2.4 Waterfall diyagramı 31
Şekil 2.6 Makine öğrenmesi teknikleri 42
Şekil 3.1 Araç yol testleri 50
Şekil 3.2 Veri toplama için araçtaki sensör konumları 52
Şekil 3.3 Testlerde kullanılan sensörler (a) mikrofon; (b) ivmeölçer 53
Şekil 3.4 Hava emiş ve egzoz orifisi mikrofon ölçüm konumları 54
Şekil 4.1 Hızlanma testi sırasında frekans alanındaki iç mekân gürültüsü... 57
Şekil 4.2 Rastgele sürüş koşullarında RPM ve araç hızı verisi 58
Şekil 4.3 Rastgele sürüş koşullarında zamana bağlı mikrofon verileri 59
Şekil 4.4 Rastgele sürüş koşullarında frekansa bağlı mikrofon verileri 60
Şekil 4.5 Sürüş verilerine dayalı GTS analiz akış şeması 60
Şekil 4.6 Değişkenlerin yoğunluk dağılımı (11 Hz Bandı) 66
Şekil 4.7 Rastgele orman grafiği parametre seçimi 71
Şekil 4.8 Tahmin edilen eğri ve gerçek eğri 72
Şekil 4.9 Model tahmini önem parametreleri……..……75
Şekil 4.10 Regresyon uygunluk eğrisi 75
Şekil 4.11 Makine öğrenimi modellerinin kıyaslanması 76
Şekil 5.11 Hz bandındaki tüm koltuk gürültüsünün 64 dB(A) için her değişkenlerin geliştirme hedefleri…….……..85

TABLO LİSTESİ

Tablo 2.1 Motor sıralamaları ve tanımları/kaynakları 31

Tablo 3.1 Veri lokasyonlarına karşılık veri toplama cihazı adresleme kullanımı 52

Tablo 3.2 Testlerde kullanılan araç özellikleri……. 52

Tablo 3.3 Sensör özellikleri 53

Tablo 4.1 GTS verilerinin istatistik hesaplamaları.....66

Tablo 4.2 Tahmin Özet Sonuçları 66

Tablo 4.3 Korelasyon Tablosu…….. 59

Tablo 1.1 İyileştirme hedefleri…...…….71

ÖZET

MAKİNE ÖĞRENİMİ VE VERİ BİLİMİ İLE GÜRÜLTÜ, TİTREŞİM VE SERTLİK ANALİZİNİN GELİŞTİRİLMES

Kemal DEMİR

Makine Mühendisliği Anabilim Dalı

Makine Teorisi ve Kontrol Programı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Cihan DEMİR

Bu tez çalışması, içten yanmalı motora sahip büyük ticari yolcu otobüslerinde araç içi konforu etkileyen temel parametreler olan gürültü, titreşim ve sertlik (GTS) seviyelerinin iyileştirilmesine yönelik, makine öğrenimi temelli bütüncül bir değerlendirme ve analiz yaklaşımı geliştirmeyi amaçlamaktadır. GTS unsurları hem araçların algılanan kalitesini hem de yolcu memnuniyetini doğrudan etkileyen kritik göstergelerdir. Bu nedenle, araç geliştirme süreçlerinde GTS karakteristiklerinin doğru analiz edilmesi ve iyileştirme hedeflerinin isabetli bir şekilde belirlenmesi büyük önem taşır. Mevcut endüstriyel uygulamalarda kullanılan geleneksel GTS teşhis yöntemleri (örneğin Transfer Patika Analizi- TPA, Operasyonel Deplasman Analizi- ODS) doğrusal sistem varsayımları altında çalışmakta, yüksek zaman ve kaynak maliyetlerine sebep olmaktadır. Bu tezde ise, doğrusal olmayan sistem davranışlarını da dikkate alabilen ve daha geniş veri kümeleriyle çalışabilen, veri bilimi odaklı alternatif bir yöntem önerilmiştir.

Çalışma kapsamında, makine öğrenimi algoritmaları (özellikle Rastgele Orman), keşifsel veri analizi (EDA), korelasyon analizi, değişken önem sıralaması ve hassasiyet analizi gibi yöntemlerle desteklenen yeni bir GTS değerlendirme süreci geliştirilmiştir. Bu yöntem; büyük hacimli test verileri kullanarak, araçtaki her bir potansiyel gürültü ve titreşim kaynağının hedef iç mekân gürültüsüne olan etkisini sayısal olarak ortaya koymaktadır. Ayrıca bu etkiler ışığında, daha doğru ve uygulanabilir sistem hedefleri belirlenmesine olanak tanımaktadır. Rastgele orman algoritması ile diğer makine öğrenimi yöntemleri de kıyaslanarak yorumlanmıştır. Geleneksel TPA ve ODS yöntemleri ile karşılaştırıldığında, önerilen yaklaşım hem veri işleme süresini kısaltmakta hem de doğruluk ve genellenebilirlik açısından daha başarılı sonuçlar sunabilmektedir.

Deneysel çalışmalar kapsamında, önerilen yaklaşımın gerçek yol koşullarında uygulanabilirliğini test etmek üzere iki adet yol testi gerçekleştirilmiştir. Bunlardan ilki, tam açık gaz kelebeği (WOT) altında gerçekleştirilen hızlanma testidir. Bu test, araç içi gürültünün hangi frekans bantlarında yoğunlaştığını belirlemek ve analizlerde odaklanılacak hedef frekans aralığını seçmek amacıyla yapılmıştır. Özellikle 11 Hz frekans bandı, bu açıdan öne çıkmış ve çalışmanın odak noktası haline gelmiştir. İkinci test ise, 15 dakikadan uzun süreli rastgele sürüş koşullarında gerçekleştirilmiştir. Bu testte, toplamda 22 kanal üzerinden (7 mikrofon + 5 adet üç eksenli ivmeölçer ile) çoklu sensör verileri toplanmıştır. Elde edilen veriler, zaman alanından frekans alanına dönüştürülerek analiz edilmiştir.

Analiz sürecinde, toplanan veriler öncelikle istatistiksel olarak incelenmiş, çıkıntı veriler (outliers) keşifsel veri analizi ile tespit edilerek temizlenmiş ve ardından korelasyon analizleri yapılmıştır. Yapılan analizler, motor, hava emiş ve egzoz sistemlerinin iç gürültü üzerindeki etkilerinin oldukça yüksek olduğunu göstermiştir. Örneğin, motor kaynaklı titreşim ile koltuk içi gürültü seviyesi arasında %75'in üzerinde korelasyon tespit edilmiştir. Ayrıca, hedef olarak belirlenen 64 dBA araç içi ses seviyesinin sağlanabilmesi için motor gürültüsünün 95.53 dBA'nın altında tutulması gerektiği belirlenmiştir. Rastgele Orman algoritması sayesinde, bu ilişkiler doğrusal olmayan yapıları da içerecek şekilde modellenmiş ve klasik yöntemlerin ulaşamadığı doğruluk seviyelerine ulaşılmıştır.

Bununla birlikte, çalışma sadece korelasyon analizi ile sınırlı kalmamış; değişken önem analizi ve hassasiyet analizi gibi ileri yöntemlerle, GTS karakteristiğine en fazla etki eden bileşenler sıralanmış ve bu bileşenler üzerinde yapılacak tasarımsal değişikliklerin iç mekân gürültüsüne etkisi sayısal olarak değerlendirilmiştir. Böylece mühendislerin iyileştirme hedeflerini doğru belirleyebileceği sezgisel ve sayısal bir karar destek sistemi sunulmuştur.

Sonuç olarak, bu tez çalışması ile büyük veri ve makine öğrenimi tekniklerinin araç geliştirme süreçlerine etkin bir şekilde entegre edilebileceği gösterilmiştir. Klasik yöntemlerin zaman alıcı ve parçalı yapısına karşın, önerilen yaklaşım; daha kısa sürede, daha az testle, daha fazla bilgiye ulaşmayı mümkün kılmakta ve mühendislik süreçlerini hem hız hem de maliyet açısından önemli ölçüde optimize etmektedir. Literatürde, özellikle ticari otobüs segmentinde bu denli büyük hacimli GTS verileriyle doğrudan çalışan, korelasyon-hassasiyet temelli ve doğrusal olmayan modellemeye dayalı bütüncül bir yaklaşıma nadiren rastlanmaktadır. Bu yönüyle çalışma, yalnızca akademik katkı değil, aynı zamanda endüstriyel uygulama potansiyeli de taşımakta; araç geliştirme, GTS mühendisliği ve veri odaklı sistem optimizasyonu alanlarına önemli bir katkı sunmaktadır.

Anahtar Kelimeler: büyük veri, veri bilimi, GTS, korelasyon analizi, hassasiyet analizi.

ABSTRACT

IMPROVING NOISE, VIBRATION AND HARSHNESS ANALYSIS WITH MACHINE LEARNING AND DATA SCIENCE

Kemal DEMİR

Department of Mechanical Engineering

Master of Science

Supervisor: Prof. Dr. Cihan DEMİR

This thesis presents a novel, data-driven and machine learning-supported analysis and evaluation framework to improve Noise, Vibration, and Harshness (NVH) characteristics in large commercial passenger buses equipped with internal combustion engines. NVH characteristics are among the most critical parameters affecting perceived vehicle quality and passenger comfort. Therefore, accurately analyzing NVH components and determining targeted improvements are of great importance in automotive development processes. Conventional NVH diagnostic methods—such as Transfer Path Analysis (TPA), Operational Deflection Shape (ODS), Frequency Response Function (FRF), and Acoustic Transfer Function (ATF)—often rely on linear system assumptions and extensive testing procedures. This study, by contrast, proposes a more flexible and comprehensive method that incorporates nonlinear relationships and processes large datasets with advanced data science techniques.

The core methodology includes machine learning algorithms, especially the Random Forest model, combined with exploratory data analysis (EDA), correlation analysis, variable importance ranking, sensitivity analysis, and optimization-based

target selection. The proposed method numerically identifies the contribution of each potential noise and vibration source to interior cabin noise. Furthermore, it enables the accurate selection of system-level targets, facilitating a more informed and efficient design process. Compared to traditional approaches, this framework reduces the need for time-consuming physical testing and provides higher accuracy and generalizability in NVH estimation.

Two separate road tests were conducted to validate the proposed method under real driving conditions. The first test involved wide-open throttle (WOT) acceleration conditions to identify critical frequency bands for cabin noise, with particular emphasis on the 11 Hz range. The second test was carried out under random driving conditions lasting over 15 minutes, during which multi-channel data was recorded using 7 microphones and 5 triaxial accelerometers, resulting in 22 synchronized signal channels. These datasets were converted from time domain to frequency domain, and outliers were removed during the preprocessing phase.

Subsequent analyses revealed strong correlations between interior noise and certain vehicle systems, particularly the engine, air intake, and exhaust. For instance, the correlation coefficient between engine vibration and seat-level noise exceeded 0.751. Using the random forest model, these relationships were modeled with high accuracy, effectively capturing nonlinear dynamics. Based on the results, it was also determined that, in order to maintain a target interior noise level of 64 dBA, the engine noise must not exceed 95.53 dBA. These data-driven findings offer valuable design insights for noise mitigation.

The proposed approach also included variable importance and sensitivity analyses, identifying critical components for NVH improvement and quantifying the impact of design changes on cabin noise. This method serves as a decision support system for engineers, offering a fast, intuitive, and quantitative tool for selecting optimal design targets during early-stage development.

Unlike traditional TPA or ODS tests that are expensive and time-intensive, the proposed methodology offers a more scalable and cost-efficient solution. It achieves this by enabling real-world, data-driven optimization without the need for controlled laboratory environments or extensive prototype iterations. Furthermore,

the model's ability to process raw sensor data and integrate it directly into learning-based estimations ensures minimal data loss and maximizes analytical output.

The novelty of this thesis lies in its direct use of large-scale NVH datasets in commercial buses—an application area rarely explored in the literature—and in its effective modeling of nonlinear system behavior through ensemble machine learning. The developed method not only improves the accuracy of noise prediction but also streamlines the vehicle development process by reducing prototyping and test durations, saving both time and cost.

In conclusion, this study demonstrates that integrating machine learning with NVH engineering provides a significant leap forward in understanding and optimizing the acoustic and vibrational performance of commercial vehicles. The proposed framework is not limited to the case study vehicle and can be generalized for use across various vehicle types and configurations. Therefore, it offers valuable contributions both academically and industrially, laying the groundwork for data-informed design optimization in future automotive engineering practices.

Keywords: big data, data science, NVH, correlation analysis, sensitivity analysis.

1
GİRİŞ

1.1 Literatür Özeti

Son dönemde otomotiv teknolojilerinde yaşanan hızlı dönüşüm, özellikle yapay zekâ destekli sistemlerin gelişimiyle birlikte, ticari taşıtlarda otonom sürüş fonksiyonlarının daha yaygın biçimde kullanılmasını mümkün kılmıştır. Bu teknolojiler, sürücünün görev yükünü azaltmakla kalmayıp, aracın çevreyle etkileşim kurarak çeşitli kararları bağımsız şekilde almasını da sağlamaktadır [1], [2]. Ulaşım altyapısı da bu gelişmelere paralel olarak değişmekte; yeni nesil mobilite uygulamaları, veri odaklı ve bağlantılı sistemlerin sunduğu olanaklarla şekillenmektedir [3]. Özellikle araçlar arası iletişim (V2V) ve konum bazlı sistemlerin yaygınlaşması hem sürüş güvenliğini hem de trafik yönetimini daha etkin kılmaktadır [4], [5].

Ancak, teknolojiye dair bu gelişmelerin yanında, özellikle yüksek yolcu kapasiteli ticari araçlarda konforun korunması hâlâ temel bir mühendislik zorluk alanı olarak varlığını sürdürmektedir. Araç içindeki yapısal titreşimler, motor ve dış kaynaklı gürültüler ile süspansiyon rijitliği gibi parametreler, yolculuk deneyimi üzerinde doğrudan etkilidir [6]. Bu tür etkenlerin, yani Gürültü, Titreşim ve Sertlik (GTS) parametrelerinin doğru biçimde analiz edilmesi ve iyileştirme stratejilerinin sistematik olarak geliştirilmesi, araç tasarım süreçlerinin ayrılmaz bir parçası haline gelmiştir [7].

Literatürde bu tür NVH (Noise, Vibration, Harshness) analizlerinde sıklıkla başvurulan yöntemler arasında Transfer Patika Analizi (TPA), Frekans Tepki Fonksiyonu (FRF) ve Operasyonel Deplasman Şekli (ODS) yer almaktadır [8], [9]. Bu teknikler, özellikle yapı kaynaklı gürültünün tespiti ve iletim yollarının analizinde geleneksel olarak tercih edilmiştir. Ancak bu yaklaşımlar genellikle doğrusal sistem kabulüne dayandığı için, gerçek sürüş koşullarında karşılaşılan karmaşık ve zamana bağlı dinamik davranışları yeterince temsil edememektedir [10].

Son yıllarda bu sınırlamaların aşılması amacıyla büyük veri setlerinin kullanıldığı, makine öğrenmesi tabanlı analiz yöntemlerinin geliştirilmesi üzerine çok sayıda

çalışma yapılmıştır [11], [12]. Çoklu sensör sistemlerinden elde edilen zaman serisi veriler, istatistiksel modelleme yöntemleriyle işlenerek araçtaki farklı bileşenlerin iç mekân akustik yapıya olan katkıları daha ayrıntılı biçimde ortaya konabilmektedir [13].

Makine öğrenmesi uygulamalarında ise karar ağaçları, rastgele orman algoritmaları, destek vektör makineleri ve yapay sinir ağları gibi farklı algoritmalar yaygın olarak tercih edilmektedir [14], [15]. Bu yöntemlerin önemli bir avantajı, sistemin hem doğrusal hem de doğrusal olmayan yapısını öğrenebilmesi ve çok değişkenli, büyük hacimli veri setleriyle yüksek doğrulukta çalışabilmesidir [16]. Ek olarak, değişken önem derecelendirmesi, korelasyon ölçümleri ve duyarlılık analizleri sayesinde, sistem üzerinde baskın etkiye sahip kaynakların önceliklendirilmesi ve iyileştirme hedeflerinin daha net biçimde tanımlanması mümkün hâle gelmektedir [17], [18].

Bununla birlikte, modelleme aşamasında kullanılan verilerin doğruluğu, analiz sonuçlarının geçerliliği açısından büyük önem taşımaktadır. Özellikle ölçüm sırasında oluşabilecek gürültüler, sensör kaynaklı hatalar veya veri içindeki aykırı değerler, sonuçların güvenilirliğini olumsuz etkileyebilmektedir. Bu nedenle, analiz öncesinde veri kümesinin istatistiksel kontrolü, normalleştirilmesi ve uygun filtreleme teknikleri ile temizlenmesi gerekmektedir [19].

GTS karakteristiğinin değerlendirilmesine yönelik olarak geliştirilen bu yeni nesil analiz yaklaşımları, geleneksel yöntemlerin sunduğu kısıtların ötesine geçerek daha kısa sürede, daha az test ihtiyacı ile daha isabetli öngörüler sağlamaktadır [20]. Bu sayede hem prototip ihtiyacı azaltılmakta hem de ürün geliştirme sürecinde karar alıcılar daha güçlü verilerle yönlendirilebilmektedir.

Ancak mevcut literatürde korelasyon ve hassasiyet analizlerinin GTS veri dağılımları üzerinde bu denli kapsamlı kullanıldığı örneklerin sınırlı olduğu gözlemlenmektedir. Özellikle büyük ticari taşıtlara ait çok kanallı, uzun süreli veri kümeleri üzerinden yürütülen analizler nadir bulunmakta ve araştırmacıların çoğunluğu basit sürüş testlerinden ve FRF ölçümlerinden elde edilen dar kapsamlı verilerle çalışmaktadır. Dahası, bir sistemin titreşimi veya gürültüsü değiştiğinde, bu değişimin araç içi gürültü seviyesi üzerindeki etkisini sayısal olarak tespit etmek

ve hangi düzeyde iyileştirme gerektiğini belirlemek, hâlen önemli bir mühendislik sorunudur.

Bu çalışmada, özellikle büyük ticari otobüslerde uygulamaya dönük olarak kullanılabilecek, büyük veri tabanlı bir korelasyon analizi yöntemi önerilmektedir. Öne çıkan katkılar aşağıda özetlenmiştir:

- Her bir ses veya titreşim kaynağının hedef üzerindeki etkisi, sezgisel ve kolay anlaşılır sayısal analizlerle değerlendirilmiştir.
- GTS iyileştirmesine yönelik hedef belirleme süreci, model çıktılarıyla desteklenerek daha isabetli hale getirilmiştir.
- TPA ve ODS gibi zaman alıcı klasik analiz süreçlerinin yerini, daha hızlı ve veri merkezli bir yapı almıştır.

Önerilen yaklaşım, yalnızca sürüş verilerini kullanarak her ölçüm kanalının hedef gürültüyle olan ilişkisini sayısal olarak analiz etmeye imkân tanır. Bu sistem, aynı zamanda gerekirse modelleme süreçlerinde kullanılabilecek ek veriler sağlamakta ve iyileştirme hedefleri için daha akılcı bir plan sunmaktadır. Duyarlılık analizinin bu şekilde entegre edilmesi, sistem seviyesindeki herhangi bir değişikliğin iç mekân ses seviyesi üzerindeki etkisinin de tahmin edilebilmesini mümkün kılar. Bunun yanı sıra, sistemin kabul edilebilir GTS düzeyine ulaşabilmesi için hangi parçalarda, ne kadarlık bir iyileştirme yapılması gerektiğine dair net karar noktaları da sunulmuştur.

Sonuç olarak, bu metodoloji hem geliştirme sürecinde zaman kazancı sağlamakta hem de mühendislik kararlarını destekleyecek veriye dayalı bir çerçeve sunmaktadır. Elde edilen sonuçlar tasarım aşamasında da kullanılarak, araç üzerinde yapılacak optimizasyonların önceden modellenmesine olanak tanımaktadır. Bu bağlamda, önerilen yöntemin ayrıntılı performans değerlendirmeleri Bölüm 3'te yer almakta, analiz sonuçları ve değişken etkileri Bölüm 4'te ayrıntılı olarak incelenmektedir. Bölüm 5'te, teknik istatistiklere dayalı iyileştirme hedefleri sunulmakta; nihayetinde Bölüm 6'da çalışmanın genel değerlendirmesi ve geleceğe yönelik öneriler tartışılmaktadır.

1.2 Tezin Amacı

Günümüzde taşıt endüstrisi, yalnızca teknik performans kriterleriyle değil, aynı zamanda araçların kullanıcıya hissettirdiği konfor algısıyla da rekabet etmektedir. Özellikle taşıtlardan kaynaklanan gürültü ve titreşim özellikleri, hem araç kalitesine yönelik algıyı şekillendirmekte hem de potansiyel kullanıcıların satın alma kararları üzerinde doğrudan etkili olmaktadır. Artan rekabet baskısı nedeniyle, üretici firmalar ürün geliştirme döngülerini mümkün olduğunca kısaltmakta ve bu süreci daha verimli hâle getirebilmek için yeni yöntemler aramaktadır.

Bu çalışmada, araçların gürültü ve titreşim performansını daha hızlı ve güvenilir biçimde öngörebilmek amacıyla, çeşitli sensörler yardımıyla (ivmeölçer ve mikrofonlar) farklı bileşenlerden ölçümler yapılmıştır. Veri toplama süreci, özellikle GTS parametreleri açısından kritik olan konumlara odaklanılarak gerçekleştirilmiş; ardından toplanan veriler ön incelemeye tabi tutulmuş ve istatistiksel yöntemlerle analiz edilerek modelleme öncesinde uygun şekilde düzenlenmiştir. Bu sayede, tahmin modeli için kullanılacak veri kümesinin homojenliği artırılmış ve modelin başarımı yükseltilmiştir.

Çalışmanın temel hedefi, gerçek sürüş testlerinden elde edilen çok kanallı veriler üzerinden gürültü ve titreşim arasındaki ilişkiyi transfer fonksiyonları aracılığıyla somut biçimde ortaya koymak ve bu yolla taşıt geliştirme sürecini hem zaman hem maliyet açısından daha verimli hâle getirmektir. Bu amaçla, tahminleme sürecinde Rastgele Orman algoritması tercih edilmiş, elde edilen sonuçlar alternatif makine öğrenimi modelleriyle karşılaştırılarak değerlendirilmiştir. Böylece, önerilen yöntemin hem doğruluk hem de uygulanabilirlik açısından endüstriyel kullanıma uygunluğu test edilmiştir.

1.3 Hipotez

Araçlarda hissedilen gürültü, titreşim ve sertlik (GTS) düzeyleri ile araç üzerindeki sürüş verileri arasında anlamlı istatistiksel bağlar kurulabilmektedir. Bu bağların açığa çıkarılmasında, klasik analiz yöntemlerinin ötesine geçen, büyük veri analitiğine dayalı korelasyon tekniklerinin kullanımı etkili sonuçlar vermektedir. Bu bağlamda yapılacak analizler, özellikle araç geliştirme sürecinde hedeflenmiş iyileştirmelerin daha isabetli belirlenmesine imkân tanımakta ve konfor düzeyinin

artırılmasına yönelik mühendislik yaklaşımlarına veri temelli bir zemin hazırlamaktadır.

Veri analizi sürecine entegre edilen makine öğrenimi algoritmaları sayesinde, titreşim ve gürültüye yol açan temel frekans bileşenleri tespit edilebilmekte ve bu bileşenlerin kök nedenleri sistematik olarak incelenebilmektedir. Bu yaklaşımla, yalnızca ilgili frekans aralıklarında değil, sistemin genel dinamik davranışları açısından da iyileştirme alanları ortaya konabilmektedir.

Bu tezde ortaya konan hipotezlerin doğruluğu, araç tasarımı ve mühendislik süreçlerinde GTS seviyelerinin daha etkin yönetilebileceğini göstermektedir. Yürütülen çalışmalar, özellikle sürüş deneyimini iyileştirmeyi amaçlayan mühendislik çözümlerinin daha hedefli ve etkili biçimde geliştirilmesine katkı sunmaktadır. Nihai olarak, önerilen bu yaklaşımın hem üreticiler için geliştirme süresini optimize etmesi hem de kullanıcı tarafında konfor algısını artırması bakımından çift yönlü fayda sağlayacağı değerlendirilmektedir.

2
ARAÇ GÜRÜLTÜ TİTREŞİMİ VE MAKİNE ÖĞRENİMİ TEMELLERİ

2.1 Araç Gürültü ve Titreşim Temelleri

Günlük yaşamda konforu artırmaya yönelik geliştirilen pek çok sistem, farklı mühendislik disiplinlerinin ortak ürünüdür. HVAC sistemlerinden biyomekanik çözümlere, havacılıktan otomotive kadar geniş bir yelpazede kullanılan bu teknolojiler; yalnızca işlevsel değil, aynı zamanda duyusal etkileşim açısından da titizlikle ele alınan yapılar barındırmaktadır. Bu sistemlerin her biri, belirli kullanım senaryolarına uygun olacak şekilde, birbirinden farklı kriterler doğrultusunda kurgulanmaktadır. Otomotiv sektörü de bu çok disiplinli yaklaşımın güçlü bir örneğidir.

Modern araç tasarımında, müşterinin algıladığı kaliteyi etkileyen unsurlar yalnızca görsel veya fiziksel bileşenlerle sınırlı değildir. İç mekân malzeme kalitesi, kontrol ergonomisi, araç dinamikleri, akustik performans ve yakıt tüketimi gibi nitelikler; hem bireysel hem de bütüncül olarak kullanıcı kararlarını etkileyebilmektedir. Bu nitelikler arasında çoğu zaman birbirine zıt yönlü ilişkiler olabilir. Örneğin, bir

tasarım parametresinin iyileştirilmesi, başka bir parametre üzerinde olumsuz etki yaratabilir. Dolayısıyla, otomotiv mühendisliği süreçlerinde kaçınılmaz olan bu denge arayışı, sistemler arası ödünleşim yönetimini kaçınılmaz hale getirir.

GTS (Gürültü, Titreşim ve Sertlik) özellikleri de bu bağlamda doğrudan kullanıcı konforunu etkileyen ve tasarımın erken aşamalarında ele alınması gereken önemli parametreler arasında yer almaktadır. Araç geliştirme sürecinde, GTS'yi oluşturan alt sistemlerin performansı hem bireysel parçaların hem de tüm sistemin çalışma koşulları göz önünde bulundurularak değerlendirilmelidir. Sürüş esnasında aracın maruz kaldığı çevresel ve operasyonel uyarılar, GTS karakteristiği üzerinde belirleyici rol oynar. Bu nedenle mühendislerin hem yüksek hızda seyir hem de şehir içi gibi düşük hız senaryolarında oluşabilecek titreşim ve gürültü profilini dikkate alarak sistemleri optimize etmeleri gerekir.

Yeni bir araç geliştirme süreci başlatıldığında, erken aşamalarda yapılan kıyaslama çalışmaları büyük önem taşır. Bu aşamada, mevcut pazardaki benzer ürünler incelenerek ve geliştirilecek aracın teknik kimliği, yani "DNA'sı" şekillendirilir. Özellikle GTS alanında, araç düzeyinde belirlenen hedeflerin tüm mühendislik alt sistemlerine aktarılması ve bu hedeflere uygun sistem ve bileşen yapılandırmasının yapılması gerekmektedir. Çünkü her ne kadar son kullanıcı, nihai performansı araç genelinde değerlendiriyor olsa da bu performansı etkileyen faktörler sistem alt bileşenleri düzeyinde şekillenmektedir.

Araç içi gürültü ve titreşim karakteristikleri genel olarak üç temel bileşen grubunda incelenir: güç aktarma organlarından kaynaklanan ses ve titreşim, yol kaynaklı etkiler ve aerodinamik (rüzgâr) kaynaklı sesler. Bu üç grubun her biri farklı mühendislik disiplinlerini ve tasarım stratejilerini gerektirir. Örneğin, rüzgâr kaynaklı seslerin azaltılması amacıyla yapılan çalışmalar, çoğunlukla aerodinamik gövde tasarımı, sızdırmazlık elemanları ve kapı–cam bağlantılarına odaklanırken; motor kaynaklı titreşimler için gövde rijitliği, motor yataklarının dinamik özellikleri ve yapısal sönümleme gibi parametreler öne çıkmaktadır. Benzer şekilde, yol kaynaklı gürültülerin azaltılması ise süspansiyon sistemi, lastik karakteristiği ve gövde bağlantı noktalarındaki izolasyon optimizasyonunu gerektirir.

Bu karmaşık yapının daha iyi yönetilebilmesi için, GTS alt parametrelerinin her birinin yalnızca kendi alanında değil, sistemin bütünündeki etkileriyle birlikte değerlendirilmesi gerekmektedir. Özellikle gürültü iletim yollarının anlaşılması, bu süreçte kritik bir rol oynamaktadır. Araç içerisindeki ses, genel olarak iki temel yolla yol alır: yapı kaynaklı (structure-borne) ve hava kaynaklı (air-borne). Yapı kaynaklı iletimde, mekanik titreşimler gövde elemanları üzerinden yayılırken; hava kaynaklı iletimde, ses dalgaları havayı taşıyıcı ortam olarak kullanır. Mühendislik açısından, bu iletim yollarının birbirinden ayrıştırılarak hangi bölgenin ne düzeyde katkı sağladığının belirlenmesi; çözüm stratejisinin doğru belirlenmesi açısından son derece önemlidir. Örneğin, sorun yapısal iletimdeyse, panel sertliklerinin artırılması veya bağlantı noktalarının izolasyonu öne çıkar; hava kaynaklı ise, izolasyon malzemelerinin yerleşimi veya kabin içindeki absorpsiyon oranları iyileştirilir.

Bu nedenle yapı ve hava kaynaklı ses katkılarının ayrı ayrı analiz edilmesi, sistemin daha isabetli ve maliyet-etkin biçimde iyileştirilmesine olanak tanır. Sadece ses seviyesini düşürmek değil, bu seviyeye hangi yol üzerinden katkı geldiğini anlamak, mühendislik kararlarını hedefe odaklı ve ölçülebilir hâle getirir.

2.1.1 Yapısal ve Hava Kaynaklı Gürültü

Birçok akustik olayda, sesin yayılımı doğrudan titreşimli katı yüzeyler aracılığıyla gerçekleşir. Özellikle içten yanmalı motor sistemlerinde bu durum oldukça belirgindir. Motor çalışırken gerçekleşen yanma süreci, motor bloğu ve bağlantılı parçalar üzerinde periyodik titreşimler oluşturur. Bu titreşimler, çevreleyen hava ortamına yayılarak ses dalgalarına dönüşür. Söz konusu ses dalgaları, genellikle gösterge paneli, havalandırma kanalları veya araç gövdesindeki çeşitli açıklıklar gibi bileşenlerden geçerek sürücünün ve yolcuların algı alanına ulaşır. Bu tür iletimler, literatürde “hava kaynaklı ses” (air-borne noise) başlığı altında değerlendirilir.

Bununla birlikte, motor kaynaklı akustik etkinin sadece hava yoluyla değil, aynı zamanda yapısal iletim yoluyla da gerçekleştiği bilinmektedir. Motor içinde oluşan döner hareketler ve yanma sürecinden kaynaklanan ani basınç değişimleri, motor yapısı üzerinde geniş bir frekans spektrumuna yayılan titreşim kuvvetleri oluşturur. Bu kuvvetler, motor bağlantı noktaları (örneğin motor takozları) aracılığıyla şasiye

ve oradan da araç gövdesine iletilir. Yapının bu şekilde titreşim enerjisini iletmesi sonucunda, araç panelleri ve diğer yapısal elemanlar üzerinden düşük frekanslı ses yayılımı meydana gelir. Bu olgu, "yapı kaynaklı ses" (structure-borne noise) olarak tanımlanır.

Hava ve yapı yoluyla gerçekleşen bu iki temel iletim biçimi, araç akustiği açısından farklı karakteristikler gösterir ve ayrı ayrı değerlendirilmesi gereken mühendislik konularıdır. Özellikle iç mekânda hissedilen sesin hangi iletim yoluyla baskın hâle geldiğini belirlemek, uygulanacak iyileştirme stratejisinin türünü ve maliyetini doğrudan etkilemektedir.

2.1.2 Araçlarda Gürültü Kaynakları ve İletim Yolu

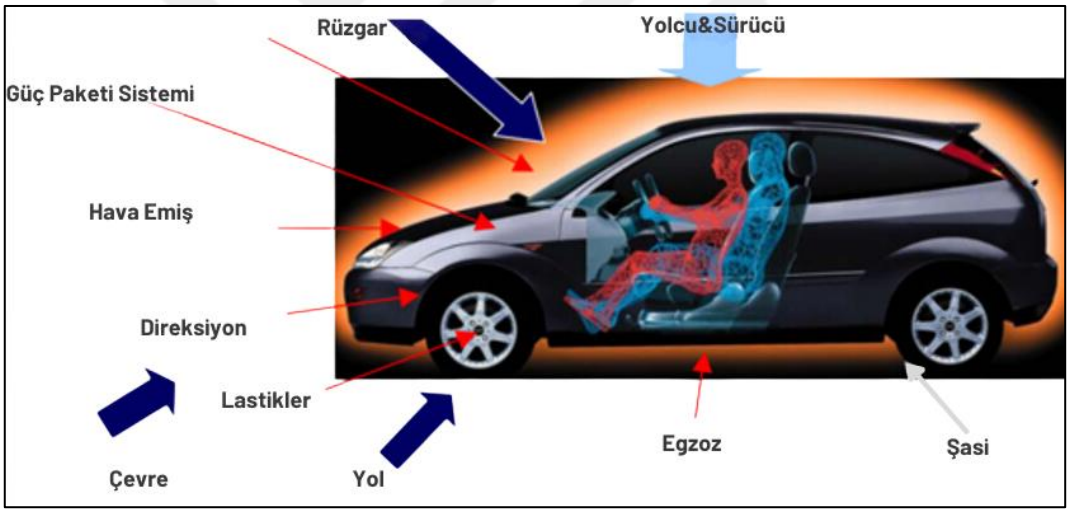
Araçlar, işletme sırasında hem kendi mekanik ve dinamik bileşenlerinden hem de dış çevreden kaynaklanan çeşitli uyarımlara maruz kalmaktadır. Bu uyarımlar kimi zaman düzenli ve öngörülebilir biçimde (örneğin sabit devirli bir motorun oluşturduğu harmonik titreşimler gibi) ortaya çıksa da gerçek sürüş koşullarında karşılaşılan etkilerin önemli bir bölümü rastgele karakter taşır. Yol pürüzleri, ani hızlanmalar, rüzgâr türbülansları gibi çevresel etkenler; zamana bağlı, düzensiz ve çok frekanslı titreşim ve gürültü profillerine neden olur. Bu rastgele uyarım karakteri, araç akustik performansının analizinde dikkate alınması gereken temel dinamik faktörlerden biridir.

2.1.2.1 Güç Aktarma Sistemlerinin Gürültü ve Titreşimleri

Güç aktarma organlarına ilişkin GTS (Gürültü, Titreşim ve Sertlik) değerlendirmesi, motor ve şanzıman biriminden başlayarak nihai tahrik sistemine tüm gürültü ve titreşim üretim süreçlerini kapsar. Özellikle içten yanmalı motorlarda, yanma işlemi sırasında ortaya çıkan akustik olaylar bu sistemin temel kaynakları arasındadır. Motor, hava emişi sırasında belirgin bir gürültü karakteri üretir; bu durum, özellikle yüksek yük altında çalışırken daha da belirgin hâle gelir. Silindir içerisinde gerçekleşen patlama, motor bloğu boyunca yapı üzerinden yayılır ve bu titreşim, gövde panellerinden hava ortamına aktarılır. Sonuç olarak, bu ses dalgaları aracın iç mekânına ulaşarak sürücü ve yolcular tarafından algılanabilir hâle gelir.

Motorun içinde yer alan döner kütleler (krank mili, eksantrik mili, pistonlar vb.) hem dönme hareketinden hem de yanma sürecinden kaynaklanan kuvvetlerin yayılmasına neden olur. Bu kuvvetler, özellikle motor takozları ve alt şasi bağlantı noktaları aracılığıyla aracın gövdesine iletilir. Yapılan titreşim iletimi, panel rezonanslarını tetikleyerek düşük frekanslı yapı kaynaklı ses oluşumuna zemin hazırlar. Bunun yanı sıra, yanma sonrası ortaya çıkan egzoz gazlarının yüksek sıcaklık ve basınçla dışarı atılması da, egzoz çıkışı civarında titreşimli ve darbeli bir gürültü bileşeni yaratır.

Tüm bu bileşenler birlikte değerlendirildiğinde, güç aktarma organları kaynaklı GTS etkilerinin hem hava kaynaklı hem de yapı üzerinden iletilen seslerle iç mekânda hissedildiği görülmektedir. Bu kapsamlı ses ve titreşim yayılımının genel yapısı, Şekil 2.1'de görsel olarak özetlenmiştir.



Şekil 2.1 Araç gürültü ve titreşim kaynakları [21]

2.1.2.2 Hava Emiş Sistemi Gürültüsü

Araç emiş sistemi aşağıdaki ana işlevleri yerine getirir

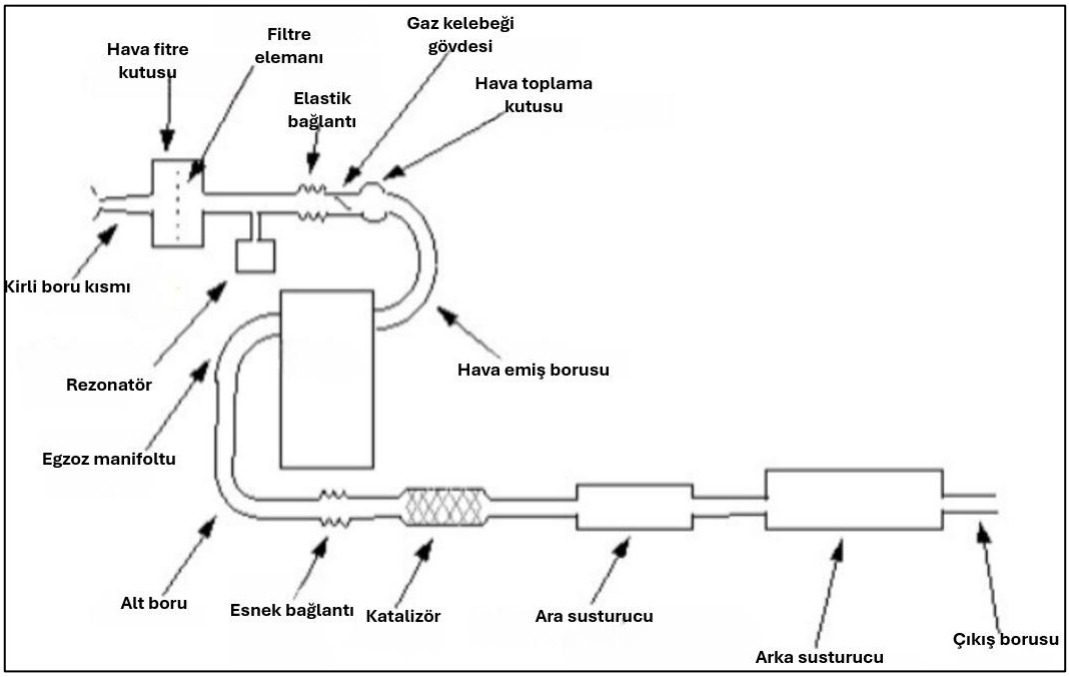
• Motora giden kanal: Emme deliği çoğunlukla hava akımına, örneğin motor bölmesine yerleştirilir. Amaç, hacimsel verimliliği artırmak için emme havasını mümkün olduğu kadar soğuk sağlamaktır.

• Partikül Filtresi: Filtre elemanı havanın gerekli hacmini partiküllerden filtreler ve bu nedenle yeterince büyük olmalı ve gerekli servis ömrünü sağlamalıdır.

• Dinamik performans ayarı: Valf yüzeyini hava toplama kutusuna bağlayan boruların uzunluğu, istenen motor hızında motorun nefes almasını iyileştirecek şekilde ayarlanır.

• Gürültü Azaltımı: Hava emiş sistemi, yayılan gürültü seviyelerinin azaltılması için kritik frekanslara ayarlanmalıdır. Özellikle benzinli motorlarda, hava emme sistemi genel iç gürültüye en çok katkıda bulunan faktörlerden biri olarak yaşanmaktadır.

Bir emme ve egzoz sisteminin şeması Şekil 2.2 gösterilmiştir.



Şekil 2.2 Hava emiş ve egzoz sistemi bileşenleri

Araçlarda hava emişinden kaynaklanan gürültünün azaltılması, genellikle iki temel prensibe dayalı olarak gerçekleştirilir. Bunlardan ilki, geniş bir frekans spektrumuna etki edebilen ve bir tür genişletme odası görevi gören hava filtre kutusunun kullanılmasıdır. İkincisi ise, daha dar bir frekans bandına odaklanan ve rezonans ilkesine göre çalışan rezonatör elemanıdır. Bu iki bileşen birlikte, hem geniş bant hem de belirli rezonans frekanslarında etkin bir sönümleme sağlamayı amaçlar.

Hava emiş sistemi, genellikle gövdenin belirli noktalarına sabitlenmiş olduğundan, motorun hava çekişi sırasında oluşan salınımlar doğrudan taşıtın yapısal elemanlarına aktarılabilir. Bu durum, gövde üzerinde istenmeyen titreşimlerin oluşmasına ve dolaylı olarak iç mekânda hissedilen gürültünün artmasına neden

olabilir. Özellikle yapı kaynaklı bu tür uyarımların azaltılabilmesi için, hava filtre kutusu ile motor arasında belirli bir esneklik sağlayan ara bağlantı elemanları kullanılır. Bu amaçla kullanılan esnek kaplinler, titreşimin gövdeye doğrudan iletimini engelleyerek hem yapı ömrünü artırmakta hem de sürüş konforunu desteklemektedir.

2.1.2.3 Egzoz Sistemi Gürültüsü

Egzoz sistemi, içten yanmalı motorlarda silindirlerde gerçekleşen yanma sonrası oluşan gazların dış ortama güvenli ve düzenli şekilde atılmasını sağlayan temel yapıdır. Bu sistemin birincil görevi, yanmış egzoz gazlarını dışarı taşımaktır; ancak bu işlevi yerine getirirken aynı zamanda çevre mevzuatlarına uygun olarak emisyon değerlerinin kontrol altında tutulması da büyük önem taşır. Bu bağlamda egzoz hattı, yalnızca akışkan dinamiği değil, aynı zamanda çevresel etki ve akustik performans gereksinimlerine göre de optimize edilmelidir.

Motor performansının korunması açısından, egzoz gazlarının sistemde oluşturduğu karşı basınç kritik bir parametredir. Bu nedenle egzoz tasarımı yapılırken, emisyon kontrol ekipmanları ve susturucular gibi bileşenler, mümkün olduğunca düşük karşı basınç yaratacak şekilde yapılandırılmalıdır. Bununla birlikte, egzoz sistemleri gürültü kontrolü açısından da dikkatle ele alınması gereken bir başka önemli kaynaktır. Özellikle egzoz çıkışında meydana gelen ani basınç boşalması hem yüksek frekanslı hem de darbeli ses bileşenlerine neden olur. Bu sesler, uygun sönümleme elemanlarıyla zayıflatılmadığı takdirde araç içi gürültüye belirgin şekilde katkı sağlar.

Egzoz sisteminden kaynaklanan sesin araç iç mekânına etkisi iki ana yolla gerçekleşir (bkz. Şekil 2.2). İlk olarak, dış ortama salınan gazlardan doğan hava kaynaklı ses bileşeni, egzoz sisteminin açıklıklarından yayılarak araç çevresinde akustik bir etki yaratır. Bu bileşen, genellikle susturucu tasarımı ve çıkış yönlendirmesiyle kontrol altına alınır. İkinci bileşen ise yapı üzerinden iletilen titreşim kaynaklı sestir. Egzoz borularında ve susturucularda oluşan mekanik titreşimler, montaj noktaları aracılığıyla araç gövdesine aktarılabilir ve bu durum düşük frekanslı, yapı kaynaklı gürültüye neden olabilir.

Bu tür yapısal iletimin azaltılabilmesi amacıyla, egzoz askı elemanlarının işlevi oldukça kritiktir. Elastomer tabanlı bağlantı parçaları, egzoz sisteminden gövdeye

aktarılan titreşimlerin sönümlenmesini sağlayarak iç mekânda hissedilen rahatsız edici ses düzeylerini azaltmada önemli rol oynar. Böylece hem sürüş konforu artırılır hem de taşıtın genel akustik karakteristiği iyileştirilmiş olur.

2.1.2.4 Motordan Yayılan Gürültü

İçten yanmalı motorlar, taşıtlarda hem güç üretiminden hem de önemli düzeyde akustik ve dinamik uyarımdan sorumlu olan başlıca kaynaklardır. Motor çalışması sırasında ortaya çıkan sesler, farklı frekans aralıklarında ve çeşitli iletim yollarıyla araç iç mekânına ulaşır. Bu nedenle, motor kaynaklı gürültü iletimini hem hava hem de yapı üzerinden ele alan kapsamlı bir analiz yaklaşımı gereklidir. Güç aktarma sistemine yönelik GTS geliştirme süreçlerinde, bu iki ana iletim yolunun birlikte değerlendirilmesi kaçınılmazdır.

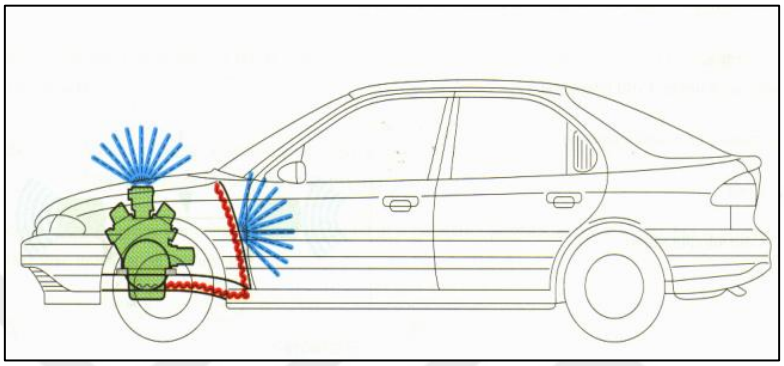
Motor bloğu ve silindir kapağı gibi temel yapısal bileşenlerden yayılan sesler genel olarak iki grupta incelenebilir. İlk grup, mekanik bileşenlerin (örneğin kam mili, valf takımı, pistonlar ve krank mili) hareketi sonucunda oluşan mekanik etkileşimlerle ortaya çıkar. Bu tip sesler çoğunlukla yapısal titreşim kaynaklıdır ve motorun iç dinamiklerinin dış yapıya iletimiyle yayılır. İkinci grubu ise, silindir içindeki yanma sürecine bağlı olarak ortaya çıkan gaz basıncı değişimlerinin motor yapısına ilettiği kuvvetlerin oluşturduğu sesler oluşturmaktadır. Bu sesler, hava ortamında yayılarak motor bölmesinden ve gövde açıklıklarından geçip araç içine ulaşabilir. Bu durum hava kaynaklı motor gürültüsü olarak tanımlanır.

Özellikle dizel motorlar, yüksek basınçla çalışan yakıt enjeksiyon sistemleri ve yanma karakteristikleri nedeniyle belirgin bir ses profiline sahiptir. Bu tür motorlarda yanma gürültüsünün şiddeti; ray basıncı, ana enjeksiyon başlangıç zamanlaması ve ön enjeksiyon gibi parametrelerden doğrudan etkilenmektedir. Yanmanın temel dinamikleri bu çalışmanın kapsamı dışında tutulmakla birlikte, akustik performansa olan etkisi önemle vurgulanmaktadır.

Motor kaynaklı gürültünün yalnızca hava yoluyla değil, aynı zamanda yapı üzerinden de yayıldığı bilinmektedir. Yanma ve döner hareketler sonucu motor üzerinde oluşan kuvvetler, bağlantı elemanları aracılığıyla şasiye iletilmektedir. Bu kuvvetler genellikle motor ve şanzıman takozları üzerinden gövde panellerine aktarılır. Kauçuk ya da hidrolik yapıda olan bu takozlar, belirli frekanslarda titreşim sönümleme özelliği gösterse de tüm titreşim enerjisini absorbe edemez. Geriye

kalan titreşim enerjisi, gövde yüzeylerinde uyarım yaratarak yapı kaynaklı gürültünün oluşmasına sebep olur. Bu mekanizma, özellikle düşük frekanslı sesler için iç mekânda hissedilen titreşimin başlıca kaynağıdır.

Bu çift yönlü iletim mekanizmalarının genel yapısı ve etkileşimi, Şekil 2.3'te şematik olarak sunulmuştur. Hava ve yapı kaynaklı motor gürültüsünün ayrıştırılması ve ayrı ayrı analiz edilmesi, GTS performansının iyileştirilmesine yönelik uygulanacak mühendislik çözümleri için temel bilgi sağlamaktadır.



Şekil 2.3 Yapı kaynaklı ve hava kaynaklı motor gürültüsü yayılımı

En önemli uyarıcı olan içten yanmalı motorun aracın genel GTS'si üzerindeki etkisini anlamak için; Öncelikle motor uyarma mekanizmasının temelleri ve motor sıra tanımı ele alınacaktır.

Bir GTS düzeni basitçe, fenomeni üreten dönen kaynağın dönme hızının sabit bir katı olan bir frekanstaki sinüzoidal bir fenomen olarak tanımlanabilir. Sıra, motor krank mili dönüş hızı, dişli ağı, ateşleme frekansı vb. gibi temel periyodik süreçlerin katları olarak ifade edilir.

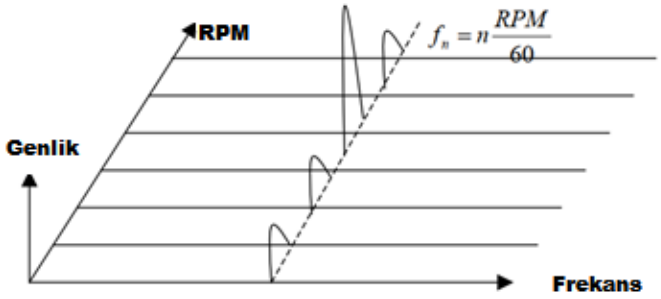
Dönen bir bileşenin n'inci dereceden dönme frekansı şu şekilde hesaplanabilir:

$$f_n = \frac{RPM}{60}\ x\ Sıra \tag{2.1}$$

f_n dönme frekansıdır, s sıra sayısıdır

RPM, dönen bileşenin dakikadaki devridir.

Dönme hızı değiştikçe bu sinüzoitlerin genliğini belirlemek için sıra izleme yöntemi kullanılır. Tipik bir üç boyutlu şelale grafiği, şekil 2.4'te görüldüğü gibi tüm spektrumların aynı anda görülmesini sağlar.



Şekil 2.4 Waterfall diyagramı

Motor sıralamaları, motor kaynaklı gürültü, titreşim ve sertlik (GTS) problemlerinin belirlenmesinde temel teşhis araçlarından biridir. Bu sıralamalar, motorun krank mili dönüş hızına bağlı olarak tanımlanır ve motorun ürettiği periyodik uyarımların frekans karakteristiklerini ortaya koyar. N silindirli bir dört zamanlı içten yanmalı motorda, her krank mili devrinde N/2 adet ateşleme gerçekleşir. Bu düzenli ateşleme darbeleri, motor üzerinde periyodik tork salınımları oluşturur ve bu salınımlar sinüzoidal bileşenlere ayrıştırılabilir.

Motor torkunda oluşan bu dalgalanmalar yalnızca ateşlemeden değil, aynı zamanda motorun döner kütlelerinin –örneğin pistonlar ve biyellerin– atalet kuvvetlerinden de kaynaklanmaktadır. Özellikle silindirler arasında meydana gelen yanma basıncı farklılıkları, krank milinde 0,5 harmoniklerinin oluşmasına neden olur. Bu harmonikler, motor sıralamasında ikinci dereceden titreşim kaynakları olarak değerlendirilir.

Bunun yanı sıra, motor bloğunun ve yataklarının rijitlik sapmaları, ilave harmonik bileşenlerin ortaya çıkmasına yol açar. Bu durum hem motor yapısının hem de taşıyıcı sistemlerin belirli frekanslarda rezonansa girme riskini artırabilir. Krank milinin geometrik ve yapısal sapmaları ise birincil harmoniklerin motor üzerine uygulanmasına neden olur ve bu harmonikler, özellikle düşük devirli sürüş koşullarında belirgin biçimde hissedilebilir.

Bu tür dinamik etkilerin doğru anlaşılması, motor GTS analizlerinde frekans bazlı çözümler üretilmesi açısından oldukça önemlidir. Söz konusu sıralama frekansları ve bunların kaynakları, sistematik olarak Tablo 2.1'de özetlenmiştir.

Tablo 2.1 Motor sıralamaları ve tanımları/kaynakları

Motor Sıraları	Motor sıralamaları ve tanımları/kaynakları
2,4,6 …	**I4'lerde birincil ateşleme torku**
3,6,9 …	**I6'larda ve V6'larda birincil ateşleme torku**
4,8,12 …	**V8'lerde birincil ateşleme torku**
1/2,1,3/2	**Silindirden silindire ateşleme basıncı değişimi, eşit olmayan egzoz veya emme nedeniyle oluşan sıralar**
Birincil ± 1/2	**Bir silindirin yakınındaki yerel sapmadan kaynaklanan sıralar**
Birincil ± 1	**Krank mili burulmasından kaynaklanan sıralar**

Motor sırası analizi yapılırken, incelenen sistemin mekanik yapısına bağlı olarak belirli uyarım sıralarının önceliklendirilmesi gerekmektedir. Örneğin, dört silindirli bir dört zamanlı motorda, genellikle ikinci dereceden ve onun katları olan uyarım kuvvetlerinin daha baskın olduğu bilinmektedir. Bu tür temel bilgiler, motor kaynaklı titreşim ve gürültü bileşenlerinin doğru şekilde ayrıştırılması açısından kritik öneme sahiptir.

Analiz sürecinde dikkat edilmesi gereken bir diğer önemli unsur ise çözünürlük ayarlarının doğru yapılandırılmasıdır. Özellikle frekans alanında, farklı sıraların (orders) birbiriyle karışmaması ve her bir harmonik bileşenin net şekilde ayırt edilebilmesi için uygun sıra çözünürlüğünün seçilmesi gerekir. Bununla birlikte, frekans çözünürlüğünün yeterli düzeyde olması da gereklidir; çünkü yetersiz çözünürlük, uyarım sıralarına karşılık gelen tepe noktalarının doğru şekilde tespit edilmesini zorlaştırabilir.

Frekans çözünürlüğü ile tarama hızının da dikkatli biçimde belirlenmesi gerekmektedir. Araç ivmelenmesi sırasında devir artışı çok hızlı gerçekleşirse, özellikle alt viteslerde (örneğin 1. viteste) motor devri hızla yükselir ve bu durum analiz sırasında önemli harmoniklerin frekans uzayında "sıkışmasına" neden olabilir. Bu da tepe noktalarının belirlenmesini güçleştirir. Buna karşın, analiz örneklemesi daha yavaş ivmelenmenin gerçekleştiği bir vites seçimiyle yapılırsa (örneğin 2. veya 3. viteste), motor devri daha kontrollü artar ve bu sayede her bir sıralı uyarımın spektral yansıması daha net şekilde elde edilebilir.

Dolayısıyla, motor sırası takibine yönelik testlerde en uygun veri elde edilebilmesi için; vites seçimi, tarama hızı ve frekans çözünürlüğü gibi parametrelerin birlikte optimize edilmesi büyük önem taşımaktadır. Aksi takdirde, verilerin eksik ya da hatalı yorumlanması, kritik titreşim bileşenlerinin gözden kaçmasına yol açabilir.

2.2 TPA ve ODS Testlerinin Temelleri

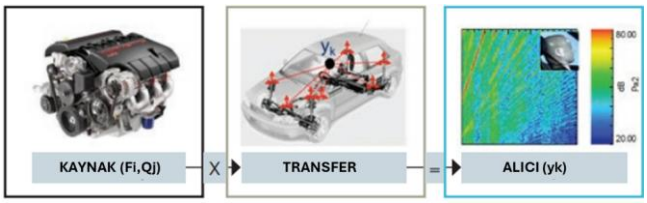
2.2.1 Transfer Patika Analizi (TPA)

Hem kaynakları hem de bir kaynak-aktarma-alıcı modelindeki aktarma yollarını nesnel olarak tanımlamaktadır. TPA yöntemiyle, gürültü katkıları; kaynak noktalarından başlayarak, aktarma yolları üzerinden alıcıya ulaşana kadar matematiksel olarak analiz edilmektedir. Mühendislik departmanları bu yöntemle belirli sorunları çözmek için değiştirilmesi gereken bileşenleri ve yapıları belirlemektedir.

TPA' nın temel prensiplerini açıklamak için, kaynak-transfer-alıcı modelindeki temel unsurları anlamak önemlidir:

- Tahrik kaynakları: Bunlar yapısal ve/veya havadan yayılan, akustik veya titreşim kaynakları olabilir. Bir araç için tipik kaynaklar arasında motor titreşimi, emiş gürültüsü, egzoz gürültüsü, yol kaynaklı titreşimler yer alır.
- Alıcı konumları: Bu genellikle akustik olarak, motorun devreye girmesi sırasında araçta yolcuların algıladığı akustik basınç gibi yerlerdir. Ayrıca direksiyon simidi veya koltuk raylarındaki titreşimler, bir ev aletinin kullanıcısının algıladığı gürültü veya taşıyıcı platform üzerindeki bir aletin çalışması nedeniyle bir uzay istasyonundaki titreşimler de alıcı konumlarıdır.

- Transfer yolları: Yapısal transfer yolları, gürültü ve titreşimin kaynak noktadan hedef konuma iletildiği fiziksel montajlar ve sert bağlantılar ile temsil edilir. Havadan yayılan transfer yollarına örnek olarak titreşen paneller, emiş veya egzoz nozulları verilebilir.



Şekil 2.5 Kaynak-Aktarma-Alıcı Model Şeması

Şekil 2.5'te gösterilmiş olan model şemasının matematiksel gösterimi denklem 2.2'de verilmiştir. Denklem iki kısımdan oluşmaktır. İfadenin birinci kısmı yapı kaynaklı gürültüleri temsil ederken, ikinci kısmı hava kaynaklı gürültüleri temsil etmektedir.

$$y_k = \sum_{i=1}^{n} \mathrm{GTF}_{ik} * F_i + \sum_{j=1}^{p} \mathrm{GTF}_{jk} * Q_j \qquad (2.2)$$

Burada;

GTF_{ik}: Yapısal kaynaklı gürültü transfer fonksiyonu

F_i: Yapısal kaynaklı titreşim kuvvetleri

GTF_{jk}: Hava kaynaklı gürültü transfer fonksiyonu

Q_j: Hava kaynaklı ait akustik yükler (ses debileri)

Kaynak-transfer-alıcı yöntemi, bir hedef ya da alıcı konumdan ölçülen verileri, genellikle "kısmi basınçlar" veya "ivmeler" gibi bileşenlere ayırarak bu bileşenlerin her birinin katkılarını belirlemeye yönelik bir tekniktir. Bu kısmi katkılar, yol veya kaynaktaki operasyonel miktarlarla yazılabilir ve yol ile hedef arasındaki transfer fonksiyonu ile çarpılır. Tipik olarak, bu sonuçlar, her bir yolun hedefe katkısını gösteren bir yol katkı grafiğinde özetlenir.

Geleneksel bir TPA modelinin oluşturulma prosedürü iki adımdan oluşur:

1. Yol üzerinde veya bir şasi dinamometresinde yapılan çalışır durumda testlerden (örneğin, devreye alma, durdurma) operasyonel yüklerin belirlenmesi.
2. Yük ara yüzleri ile hedef konumlar arasındaki frekans yanıt fonksiyonlarının (FRF) hesaplanması.

Prosedür hem yapısal hem de akustik yük durumları için benzerdir, ancak pratik uygulama sinyallerin ve yüklerin doğası tarafından belirlenir. Girdi yükleri ile hedef yanıtlar arasındaki transfer fonksiyonlarının ölçümü muhtemelen en kolay gerçekleştirilebilen süreçtir ve genellikle karşılıklılık ilkesinden yararlanır; hedef konumda (örneğin, bir hacimsel debi kaynağı ile) tahrik uygulayıp, yük-yol ara yüzünde yanıtı ölçme yöntemi kullanılır.

2.2.2 Operasyonel Sapma Şekli (ODS)

ODS testi, bir yapının veya sistemin çalışma koşulları altında titreşim davranışını analiz etmek için kullanılan bir yöntemdir. Bu test, bir bileşenin veya sistemin normal çalışma sırasında nasıl titreştiğini ve bu titreşimlerin hangi şekillerde gerçekleştiğini görselleştirmeye yardımcı olur. ODS testinin temel özellikleri:

1. Gerçek Zamanlı İzleme: ODS testi, yapı veya sistem çalışırken gerçek zamanlı olarak titreşim verilerini toplar. Bu, gerçek çalışma koşullarında sistemin nasıl davrandığını anlamak için önemlidir.
2. Titreşim Modları: Test, yapıdaki farklı noktaların titreşimlerini ölçerek, titreşim modlarını belirlemeye yardımcı olur. Bu, yapının hangi frekanslarda daha fazla titreşim gösterdiğini gösterir.
3. Görselleştirme: ODS testi, elde edilen verileri kullanarak titreşimlerin görsel bir temsilini oluşturur. Bu, mühendislerin ve tasarımcıların, sorunlu alanları kolayca tanımlamasına ve anlayabilmesine olanak tanır.
4. Problem Tespiti: Yapının hangi bölgelerinin aşırı titreşimlere maruz kaldığını belirlemek için kullanılır. Bu, tasarım iyileştirmeleri veya onarımlar için önemli bir adımdır.
5. Farklı Uygulamalar: ODS testleri, otomotiv endüstrisi, inşaat mühendisliği, havacılık ve diğer birçok alanda kullanılır. Araçların, makinelerin veya yapıların performansını optimize etmek için faydalıdır.

ODS Test Süreci

1. Veri Toplama: Titreşim ölçüm cihazları kullanarak, sistemin farklı noktalarındaki titreşimler kaydedilir.
2. Veri Analizi: Toplanan veriler analiz edilir ve belirli bir frekansta meydana gelen titreşim davranışları incelenir.
3. Görselleştirme: Elde edilen veriler, grafik veya animasyonlar aracılığıyla görselleştirilir. Bu, mühendislerin sorunları daha iyi anlamasına yardımcı olur.

Gerçek işletim koşullarındaki titreşimlerin ODS çözümlemesi için, frekans düzleminde olan yer değiştirme cevabı elde edilir.

$$X(\omega) = [(K - \omega^2 M) + i\omega C]^{-1} F(\omega) \tag{2.2}$$

Burada:

- $X(\omega)$: $Frekans\ domaininde\ yer\ değiştirme\ (ODS)$
- $F(\omega)$: $Dış\ kuvvetlerin\ frekans\ domainindeki\ etkisi$
- ω : $Frekans$
- M, K, C : $Kütle, sertlik\ ve\ sönüm\ matrisleri$

Bu denklem, yapının işletim koşullarında, özellikle dış kuvvetlerin etkisiyle nasıl hareket ettiğini ve titreşim şekillerini tanımlar.

ODS testinde, genellikle yapının her bir noktası için belirli bir frekansta yer değiştirme verileri elde edilir ve Hareket Transfer Fonksiyonu (HTF) olarak adlandırılır. Bu veriler, yapının belirli bir frekanstaki şekil deformasyonunu gösterir. Şekil deformasyonunun görselleştirilmesi, özellikle yapının dinamik analizlerini daha anlaşılır hale getirmektedir.

Bir yapının bir noktasındaki hareketin, başka bir noktadaki hareketle ilişkisini incelemek için kullanılan bir diğer analiz aracı da hareket transfer fonksiyonudur. Bu fonksiyon, farklı noktalar arasındaki ilişkileri ortaya koyarak, yapının titreşimsel / dinamik davranışlarını anlamayı sağlar.

$$HTF = \frac{X_{çıktı}(w)}{F_{girdi}(w)} \tag{2.3}$$

Burada:

- $X_{çıktı}$: $Çıkış\ noktasındaki\ yer\ değiştirme$
- F_{girdi}: $Giriş\ noktasındaki\ kuvvet$

Bu fonksiyon, yapının titreşim yanıtlarını dış kuvvetlere karşı nasıl tepkiler verdiğini gösterir.

Operasyonel Sapma Şekli (ODS) testi, yapıların işletim koşullarındaki titreşim davranışlarını incelemek için önemli bir araçtır. Yapısal denklemler, frekans çözümleme, modal analiz ve hareket transfer fonksiyonları gibi çeşitli teknikler, ODS testlerinin temelini oluşturur. Bu testler, yapının dinamik özelliklerini değerlendirmek ve potansiyel titreşim problemlerini çözmek için yaygın olarak kullanılmaktadır.

2.3 Ön Veri İşlemenin Temelleri

Gürültü, titreşim ve sertlik (GTS) verilerinin analiz edilebilir bir forma dönüştürülmesi, doğru sonuçlara ulaşılabilmesi açısından temel bir adımdır. Bu kapsamda, ön istatistiksel veri işleme süreci; ham verilerin anlamlı yapılar haline getirilmesi, gürültüden arındırılması ve modellemeye uygun hale getirilmesini sağlayan bir dizi işlemi içerir. GTS verileri çoğunlukla mikrofonlar, ivmeölçerler ve çeşitli titreşim sensörleri gibi algılayıcılar yardımıyla elde edilir ve tipik olarak zaman serisi biçimindedir.

Bu verilerin ham hali, sıklıkla eksik kayıtlar, aykırı gözlemler ya da yüksek gürültü içeriği gibi analiz sürecini olumsuz etkileyebilecek unsurlar barındırır. Bu nedenle, modelleme çalışmalarından önce uygulanacak ön işleme adımlarının verinin yapısal özelliklerine göre uyarlanması büyük önem taşır. Her analiz tekniği, farklı veri özellikleri gerektirebileceğinden; seçilecek filtreleme, normalizasyon ya da dönüşüm tekniklerinin, verinin hem dinamik hem de frekans yapısına uygun olması gerekmektedir.

Sonuç olarak, GTS verilerinin istatistiksel güvenilirliğinin sağlanması ve sonraki analiz basamaklarına uygun hale getirilmesi için ön işleme süreci yalnızca hazırlık değil, aynı zamanda model başarımını doğrudan etkileyen kritik bir aşama olarak değerlendirilmelidir.

2.3.1 Veri Temizleme

- Eksik Veri Doldurma: Verilerde eksiklikler varsa, bunlar ortalama, medyan, interpolasyon veya regresyon gibi yöntemlerle tamamlanabilir.
- Çıkıntı (Outlier) Tespiti: Verilerde olağan dışı büyük ya da küçük değerler (outlier) bulunabilir. Bunlar, yanlış ölçümler ya da hata kaynaklı olabilir. Bu veriler, istatistiksel testler (z-skoru, çeyrekler arası aralık gibi) kullanılarak tespit edilip ya düzeltilir ya da çıkarılır.
- Yoğunluk Dağılımı (Density Distribution), bir sürekli rastgele değişkenin olasılıklarının dağılımını tanımlayan matematiksel bir kavramdır. Özellikle sürekli olasılık dağılımları söz konusu olduğunda, yoğunluk dağılımı, olasılıkların nasıl dağıldığını ve bir değişkenin hangi aralıkta ne kadar olasılıkla gerçekleşeceğini gösteren bir fonksiyon sağlar.

Yoğunluk dağılımı genellikle iki türde kullanılır:

Olasılık Yoğunluk Fonksiyonu (OYF, PDF- Probability Density Function): rastgele bir değişkenin (X olsun), rastgele değişkene (X) tam olarak eşit bir değer alma olasılığıdır

Kümülatif Dağılım Fonksiyonu (KDF, CDF- Cumulative Distribution Function): bir rastgele değişkenin (X olsun), rastgele değişkene (X) eşit veya daha küçük bir değer alma olasılığıdır.

2.3.2 Veri Dönüşümü

- Normalizasyon ve Standardizasyon: Özellikle ivme ve gürültü verileri farklı ölçeklerde olabilir. Normalizasyon (0-1 arası) veya standardizasyon (ortalama 0, standart sapma 1) teknikleri ile verilerin aynı ölçeğe getirilmesi sağlanabilir.

- Logaritmik Dönüşüm: Veriler logaritmik bir dönüşümle daha düzgün hale getirilebilir, özellikle gürültü düzeyinin çok yüksek olduğu durumlarda.

2.3.3 Aykırı Değerlerin Belirlenmesi ve İşlenmesi

Aykırı değerler, veri setindeki normal örüntülerden uzaklaşan, genellikle hata veya bozulma sonucu oluşan verilerdir. Aykırı değerler, GTS verileri için özellikle önemlidir çünkü yanlış sensör ölçümleri veya sistem hataları bu tür verileri üretebilir. Aykırı değerlerin belirlenmesi için:

- Z-skoru (Z-Score): Verinin ortalama ve standart sapmasına dayalı olarak aykırı değerler tespit edilebilir.

$$Z = \frac{x_i - \mu}{\sigma} \tag{2.4}$$

Burada x_i:veri setindeki veriler, μ: verilerin ortalaması ve σ: verilerin standart sapmasıdır.
Genellikle ortalama z-skoru 3'ten büyük olan veriler aykırı kabul edilir.

Varyansı (standart sapmanın karesi) yüksek olan veri setlerinde, Z-skoru yöntemi daha etkili çalışabilir, çünkü büyük varyanslar, verinin dağılmasına ve dolayısıyla yüksek Z-skorlarına yol açar. Verilerin ortalama z-skoru genellikle 0 olmalıdır. Bir veri setinin z-skorlarının ortalamasının 0 olmasının nedeni, z-skorlarının standartlaştırılmış bir ölçüm olmasıdır. Yani, veri setinin ortalaması sıfır ve standart sapması 1 olacak şekilde dönüştürülmüş olur.

- ÇAA (Çeyrekler Arası Aralık, IQR Interquartile Range): Çeyrekler arası mesafe kullanılarak aykırı değerler tespit edilebilir. Aykırı değerlerin tespiti için bir diğer yaygın yöntem, çeyrekler arası aralığı (IQR) kullanmaktır. IQR, veri setinin orta %50'lik kısmını (1. çeyrek ile 3. çeyrek arasındaki fark) temsil eder. Aykırı değerler, genellikle IQR'nin dışındaki değerlere sahip gözlemler olarak kabul edilir.

  Aykırı değerler, genellikle şu koşulları sağladığında aykırı olarak kabul edilir:

$$\text{Aykırı Değer} < Q_1 - 1{,}5xIQR \; veya \; Aykırı \; Değer > \; Q_3 - 1{,}5xIQR$$

Burada Q_1: 1. $çeyrek, Q_3$: 3. $çeyrek\ ve\ IQR = Q_3 - Q_1$

- Varyans: Bir veri setindeki her bir verinin, veri setinin ortalamasından (veya beklenen değerinden) ne kadar uzak olduğunu gösteren bir istatistiksel ölçüttür. Varyans, her bir veri noktasının kare farklarının ortalamasıdır ve genellikle σ² (sigma kare) veya **s²** olarak gösterilir.

$$Varyans\ (\sigma^2) = \frac{1}{N}\sum_{i=1}^{N}(x_i - \mu)^2 \tag{2.5}$$

Burada:

- N: Veri setindeki öğe sayısı,
- x_i: Her bir veri noktası,
- μ : Veri setinin ortalamasıdır.

Düşük varyans: Veriler ortalama değere yakın ve daha az yayılmıştır. Bu, verilerin daha homojen olduğu ve daha az değişkenlik gösterdiği anlamına gelir.

Yüksek varyans: Veriler daha geniş bir aralıkta yayılmıştır ve ortalamadan büyük sapmalar göstermektedir. Bu, verilerin heterojen olduğu ve daha fazla değişkenlik gösterdiği anlamına gelir.

Bir veri setindeki her bir gözlem için, veri noktalarının ortalamadan ne kadar uzak olduğunu göstermek amacıyla varyans kullanılır. Eğer verinin varyansı yüksekse, bu, verinin büyük bir aralıkta yayılmış olabileceğini gösterir. Ancak, aşırı büyük varyanslar genellikle bazı çıkıntı değerlerin (outlier) varlığını gösterir.

Aykırı değerler genellikle ya silinir ya da düzeltilir. Bazı durumlarda, veriler aykırı değeri düzeltmek için yeniden ölçülür.

2.3.4 Filtreleme

- Düşük Geçiş Filtresi (Low-pass filter): Gürültü verilerini filtrelemek için sıklıkla kullanılan bir tekniktir. Yüksek frekanslı gürültüleri ayıklayarak veriyi daha anlamlı hale getirir.

- Yüksek Geçiş Filtresi (High-pass filter): Düşük frekanslı gürültüyü veya trendleri ayıklamak için kullanılabilir.
- Band Geçiş Filtresi (Band-pass filter): Belirli bir frekans aralığındaki bileşenlere odaklanmak için kullanılır, özellikle ivme verileri için faydalıdır.

2.3.5 Gürültü Azaltma

- Temel Bileşen Analizi (TBA, PCA (Principal Component Analysis): Veri boyutlarını azaltmak ve verideki gürültüyü azaltmak için kullanılan bir tekniktir. Veriyi en önemli bileşenlere indirgerken, gürültü genellikle düşük varyansa sahip bileşenlerde kalır.
- Dalgacık (Wavelet) Dönüşümü: İvme ve zaman serisi verilerindeki gürültüyü azaltmak için wavelet dönüşümleri kullanılarak sinyallerin farklı frekans bileşenlerine ayrılması sağlanabilir.

2.3.6 Veri Özelliklerinin Çıkartılması

- Zaman Domeninde Özellikler: Ortalama, medyan, varyans, standart sapma, maksimum, minimum gibi temel istatistiksel ölçütler hesaplanabilir.
- Frekans Domeninde Özellikler: Fourier dönüşümü ile frekans bileşenleri elde edilebilir ve verinin özellikleri frekans düzeyinde incelenebilir.
- Zaman-Frekans Özellikleri: Özellikle ivme verilerinde zaman-frekans analizi ile, verinin zaman içindeki değişimi ve frekans bileşenleri daha iyi anlaşılabilir.

Bu adımlar, ivme ve gürültü verilerini analiz etmek için genellikle izlenen temel süreçlerdir. Her adımın uygulanması, verinin özelliklerine ve hedeflenen analize göre değişebilir.

2.4 Makine Öğrenimi Temelleri

Makine öğrenimi, bilgisayarlara tıpkı insanlar gibi deneyim yoluyla öğrenme yetisi kazandırmayı amaçlayan bir yapay zekâ alanıdır. Bu yöntem, sabit ve önceden tanımlanmış matematiksel formüllere bağlı kalmaksızın, doğrudan veriler üzerinden örüntüleri keşfetmeyi ve çıkarımlar yapmayı mümkün kılar. Temel yaklaşım, veriye dayalı örneklerden öğrenerek, gelecekteki durumlara dair tahmin

gücünü sürekli iyileştirmektir. Makine öğrenimi algoritmaları, öğrenme süreci boyunca elde ettikleri deneyimle adaptif davranış sergiler; yani eğitim verisi arttıkça performanslarını da kademeli olarak yükseltirler.

Bu yaklaşım temel olarak iki ana kategoride ele alınmaktadır. Birincisi, gözetimli öğrenmedir. Bu teknikte hem girdi hem de karşılık gelen çıktı verileri bilinir ve algoritma bu eşleşmelerden yola çıkarak bir model öğrenir. Elde edilen model, daha sonra yeni veri girişleri için doğru çıktılar tahmin etmek üzere kullanılır. Sınıflandırma ve regresyon gibi alt yöntemler, gözetimli öğrenme kapsamına girer.

İkinci kategori ise gözetimsiz öğrenmedir. Bu yaklaşımda yalnızca girdi verileri mevcuttur; herhangi bir etiketli çıktı bulunmaz. Algoritma, verilerdeki benzerliklere veya yapısal örüntülere göre gruplamalar yaparak anlamlı kümeler oluşturur. Özellikle kümeleme (clustering) yöntemi, gözetimsiz öğrenmenin en yaygın uygulamalarından biridir. Bu tür algoritmalar, verideki gizli yapıları ortaya çıkarmak ve veri keşfi sürecinde kullanılmak üzere oldukça etkilidir.



Şekil 2.6 Makine öğrenmesi teknikleri

Gözetimli makine öğrenimi, belirsizlik ortamlarında geçmiş verilere dayalı olarak geleceğe yönelik tahminlerde bulunabilen modeller geliştirmeyi amaçlar. Bu yöntem, daha önce örneklenmiş veri kümeleriyle birlikte bu verilere karşılık gelen yanıtları (etiketleri) kullanarak model eğitir. Eğitilen model, karşısına çıkan yeni veri girişleri için en olası çıktıları üretmek üzere tahmin mekanizmaları geliştirir. Gözetimli öğrenme süreci, özellikle tahmine dayalı karar destek sistemleri oluşturmak için sınıflandırma ve regresyon tekniklerinden yararlanır.

- Sınıflandırma algoritmaları, yanıt değişkeni kategorik olduğunda kullanılır. Bu teknikler, verileri belirli sınıflara ayırarak hangi kategoriye ait

olduklarını öngörmeyi hedefler. Yaygın uygulama alanları arasında e-posta filtrelemesinde spam algılama, tıbbi tanılarda tümör türlerinin belirlenmesi, görüntü ve konuşma tanıma sistemleri ile kredi risk analizi yer alır.

- Regresyon teknikleri ise sürekli değişkenlerin öngörülmesini sağlar. Bu yaklaşımlar, örneğin sıcaklık dalgalanmaları, elektrik tüketimi veya finansal piyasalardaki değişken fiyat hareketlerini modellemek için kullanılır. Elektrik yük tahmini ve algoritmik ticaret bu kapsamda öne çıkan uygulamalardandır.

Öte yandan, gözetimsiz makine öğrenmesi, yalnızca girdi verilerinin mevcut olduğu durumlarda, veri setinde gizli kalan yapıları keşfetmeye yönelik olarak kullanılır. Bu öğrenme biçiminde veriler etiketlenmemiştir; algoritma veriler arasındaki benzerlikleri veya farklılıkları analiz ederek doğal kümelenmeleri tespit eder. En yaygın gözetimsiz öğrenme tekniği olan kümeleme (clustering), keşifsel veri analizi süreçlerinde önemli bir rol oynar.

Kümeleme algoritmaları, örneğin biyoinformatikte gen dizilimlerini gruplandırmak, pazarlama alanında müşteri segmentasyonları oluşturmak veya görüntü işleme uygulamalarında nesne tanıma işlemleri gerçekleştirmek gibi çok çeşitli alanlarda kullanılmaktadır. Bu sayede gözetimsiz öğrenme, veriye dair ön bilgi gerektirmeden, içsel örüntüleri ortaya çıkarmada güçlü bir analiz aracıdır. [21]

2.4.1 GTS Problemlerinde Rastgele Orman Algoritmasının Matematiksel Avantajları

GTS problemleri, sistemin giriş (titreşim, motor hızı, yol pürüzü vb.) ve çıkış (dBA gürültü, koltuk titreşimi vb.) parametreleri arasında gizli, karmaşık, lineer olmayan ilişkiler içerir. Bu ilişkiler genellikle şu şekilde ifade edilir:

$$y = f(x_1, x_2, \dots, x_n) + \in \tag{2.6}$$

- y: Hedef değişken (örneğin, sürücü koltuğundaki gürültü seviyesi)
- $\boldsymbol{x_i}$: Sensörlerden gelen giriş değişkenleri (örneğin, motor mikrofonu, süspansiyon ivmesi)
- ∈: Gürültü (ölçüm hatası veya sistemdeki belirsizlik)

Bu fonksiyon f (·), klasik yöntemlerle (TPA, ODS) genellikle lineer kabul edilir:

$$\mathrm{y} \approx \sum_{i=1}^{n} w_i x_i \tag{2.7}$$

Burada,

y: Hedef konumda (örneğin koltuk mikrofonu) ölçülen toplam gürültü seviyesi

x_i: i-inci uyarım kaynağından (örneğin motor, egzoz, lastik vb.) gelen sinyal (ölçülen veri)

w_i: i-inci kaynağın hedef üzerindeki ağırlık katsayısı ya da transfer etkisi (lineer etki katsayısı)

n: Toplam uyarım kaynağı sayısı (veri sayısı)
Her bir karar ağacı, aşağıdaki şekilde çalışan bölgesel bir karar mekanizması ile çalışır:

Oysa GTS sistemleri doğası gereği lineer olmayan davranışlar sergiler, özellikle rezonans, mod karışmaları, yapısal-bozulmalar gibi etkiler olduğunda bu lineer model yetersiz kalır.

Rastgele Orman, bir topluluk (ensemble) öğrenme yöntemidir ve aşağıdaki yapıyı içerir:

$$\hat{f}(x) = \frac{1}{T}\sum_{i=1}^{T} h_t(x) \tag{2.8}$$

T: Toplam karar ağacı sayısı

h_t: Her bir karar ağacının tahmini (örneğin regresyon ağacı)

$\hat{f}(x)$: Nihai tahmin sonucu (örneğin, iç mekân gürültüsü)

Her bir karar ağacı, aşağıdaki şekilde çalışan bölgesel bir karar mekanizması ile çalışır:

$$h_t(x) = \sum_{j=1}^{J_T} c_{tj}.I(x\epsilon R_{tj}) \tag{2.9}$$

- R_{tj}: Karar ağacının j. bölgesi
- c_{tj}: O bölgedeki ortalama tahmin değeri
- I: Gösterim fonksiyonu (örnek x, bölgeye düşüyorsa 1, yoksa 0)

Her bölge aslında bir lokal regresyon modeli gibi çalışır. Bu da GTS analizinde parça parça farklı fiziksel koşullara (farklı frekans bandı, farklı uyarım şekli) göre modellemeyi mümkün kılar.

2.4.2 Modelleme Yaklaşımı

Rastgele Orman (Random Forest, RF) algoritması hem sınıflandırma hem de regresyon problemlerini çözmek amacıyla geliştirilen, birden fazla karar ağacının bir araya gelmesiyle oluşturulan topluluk (ensemble) öğrenme yaklaşımıdır. Bu yöntem, her bir karar ağacının çıktısını bağımsız olarak değerlendirir ve nihai tahmini bu çıktılar üzerinden ortalama alarak üretir. Bu topluluk yapısı, özellikle modelin genelleme yeteneğini ve tahmin doğruluğunu önemli ölçüde artırma potansiyeline sahiptir.

RF algoritması, klasik karar ağacı yapısının ötesine geçerek, model performansını artırmak için iki temel teknik içerir: torbalama (bagging) ve rastgele alt uzay seçimi (random subspace method). Torbalama, eğitim verisinden farklı önyükleme örnekleri oluşturularak her ağaç için ayrı veri kümeleri üretir. Bu yöntem, modelin varyansını düşürerek aşırı öğrenmenin (overfitting) önüne geçilmesine yardımcı olur. Rastgele alt uzay yaklaşımı ise, her bir karar ağacı için tüm özellikler yerine rastgele seçilen alt kümelerle çalışılmasını sağlar. Bu teknik, ağaçlar arasında bağımsızlığı artırarak modelin genelleme yeteneğini geliştirir [23].

Bir diğer avantajı ise, RF algoritmasının ham veriler üzerinde doğrudan çalışabilmesidir. Bazı algoritmalar ön işleme, normalizasyon veya dönüştürme gerektirirken; RF, çoğu durumda bu işlemlere ihtiyaç duymadan uygulanabilir. Bu

da uygulama sürecini sadeleştirir ve zaman kazandırır [24]. Ayrıca, RF algoritması yalnızca tahmin amacıyla değil, özellik önemi analizi için de yaygın biçimde kullanılmaktadır. Bu sayede model, hangi değişkenlerin hedef değişken üzerindeki etkisinin daha baskın olduğunu istatistiksel olarak ortaya koyabilir.

Bu çalışmada RF algoritmasının tercih edilmesinin başlıca nedeni, araç gövdesinin dinamik tepkileri ile iç mekân gürültüsü arasındaki ilişkinin doğrusal olmayan yapılar içermesidir. Rastgele Orman modeli, birden fazla karar ağacını kullanarak doğrusal olmayan etkileşimleri başarıyla öğrenebilme yeteneğine sahiptir. Bu yönüyle, klasik matematiksel modelleme yaklaşımlarına kıyasla daha esnek ve açıklayıcı bir çözüm sunmaktadır. Ayrıca, fiziksel modelleme yöntemlerinin aksine RF, karmaşık parametrik varsayımlara veya katı başlangıç koşullarına gerek duymadan çalışabilmekte; bu da modelin daha geniş veri kümeleriyle ve daha gerçekçi koşullarda uygulanmasını kolaylaştırmaktadır.

Modelin eğitimi sürecinde, gürültü ve titreşim verileri çeşitli istatistiksel ön işleme adımlarından geçirilmiş; bu adımlar sayesinde veri kalitesi iyileştirilmiş ve tahmin doğruluğu artırılmıştır. Model eğitiminin ardından korelasyon analizleri gerçekleştirilmiş ve değişkenler arasındaki ilişki yapıları sayısal olarak değerlendirilmiştir. Bu analizler sonucunda, sistemin hangi bileşenlerinde iyileştirme yapılması gerektiğine dair öncelikler tanımlanmış ve hedef değerler oluşturulmuştur.

Model performansının değerlendirilmesi için çeşitli tahmin hata metrikleri kullanılmıştır. Bu metriklerden biri olan R Kare (R^2) değeri, regresyon analizlerinde modelin bağımlı değişken üzerindeki açıklayıcı gücünü ifade eder. Başka bir deyişle, modelin verinin varyansını ne ölçüde açıkladığını belirler. R^2 değeri ne kadar yüksekse, modelin veriye uyumu o denli güçlü kabul edilir.

R Kare değeri 0 ile 1 arasında değişir:

- $R^2 = 0$: Model, veriyi hiç açıklayamıyor demektir.
- $R^2 = 1$: Model, veriyi tamamen açıklıyor demektir.
- $R^2 = 0.75$: Model, verinin %75'ini açıklıyor demektir.

Formülü ise;

$$R^2 = 1 - \frac{Toplam\ Kalan\ Kareler\ (RSS)}{Toplam\ Kareler\ (TSS)} \quad (2.10)$$

Burada:

- TSS (Total Sum of Squares): Verinin toplam varyansı (bağımlı değişkenin ortalama değerine göre hesaplanır).
- RSS (Residual Sum of Squares): Modelin tahmin hatalarının toplamı.
-

Kök Ortalama Kare Hatası (KOKH, RMSE- Root Mean Square Error)**:** Regresyon analizlerinde ve tahmin modellemelerinde, modelin tahmin ettiği değerlerle gerçek gözlemler arasındaki farkın ortalama büyüklüğünü ölçen bir hata metriğidir. KOKH, modelin tahmin başarısını değerlendirmede yaygın olarak kullanılır ve hata büyüklüğünün anlamlı bir şekilde yorumlanabilmesi için, birimlerin modelin çıktıları ile aynı olması gerekir.

Formülü ise;

$$\text{KOKH} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \quad (2.11)$$

Burada:

- n: Gözlem sayısı (veri noktalarının sayısı)
- y_i: Gerçek gözlem değeri (i'inci veri noktasının gerçek değeri)
- $\hat{y}_i$: Model tarafından tahmin edilen değer (i'inci veri noktasının tahmin edilen değeri)
- $((y_i - \hat{y}_i)^2$: Gerçek değer ile tahmin arasındaki farkın karesi

Ortalama Kare Hatası (OKH, Mean Squared Error - MSE)**:** Modelin tahmin ettiği değerler ile gerçek gözlemler arasındaki farkların karelerinin ortalamasını verir. Bu metrik, modelin ne kadar hata yaptığını ve tahminlerinin ne kadar doğru olduğunu anlamak için kullanılır.

$$\text{OKH} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \quad (2.12)$$

- n: Gözlem sayısı (veri noktalarının sayısı)
- y_i: Gerçek gözlem değeri (i'inci veri noktasının gerçek değeri)
- $\hat{y}_i$: Model tarafından tahmin edilen değer (i'inci veri noktasının tahmin edilen değeri)
- $((y_i - \hat{y}_i)^2$: Gerçek değer ile tahmin arasındaki farkın karesi

Ortalama Mutlak Hata (OMH, Mean Absolute Error - MAE): Regresyon ve tahmin modellerinde, modelin tahmin ettiği değerler ile gerçek gözlemler arasındaki farkların ortalama mutlak değerini ölçen bir hata metriğidir. MAE, hataların büyüklüğünü göz önünde bulunduran ve her hata için aynı ağırlığı veren bir ölçüttür.

$$\text{OMH} = \frac{1}{n}\sum_{i=1}^{n}|(y_i - \hat{y}_i)| \quad (2.13)$$

- n: Veri setindeki gözlem sayısı (veri noktalarının sayısı)
- y_i: Gerçek gözlem değeri (i'inci veri noktasının gerçek değeri)
- $\hat{y}_i$: Modelin tahmin ettiği değer (i'inci veri noktasının tahmin edilen değeri)
- $|(y_i - \hat{y}_i)|$: Gerçek değer ile tahmin arasındaki mutlak fark (mutlak hata)

3
GÜRÜLTÜ TİTREŞİM TESTLERİ VE METOD

Bu çalışmanın önceki bölümlerinde, araç içi akustik karakteristiklerin değerlendirilmesinde temel oluşturan kavramlar ayrıntılı biçimde ele alınmıştır. Bu kapsamda, ses ve titreşim davranışlarının fiziksel temelleri ile, veri işleme teknikleri ve makine öğrenmesinin genel prensipleri sunulmuştur. Bu arka plan, tezin asıl amacına geçiş için gerekli teorik zemini oluşturmuştur.

Tezin temel hedefi, araç içi gürültü seviyesini tahmin etmeye ve bu gürültüyü azaltmaya yönelik bir makine öğrenimi yaklaşımı geliştirmektir. Bu doğrultuda, sürüş esnasında belirli bir frekans bandında ortaya çıkan iç mekân gürültüsünün

iyileştirilebilmesi için, bu frekans aralığında etkili olan kaynakların belirlenmesi ve bu kaynaklara yönelik iyileştirme önerilerinin ortaya konması amaçlanmıştır.

Söz konusu hedefe ulaşmak üzere, iki aşamalı yol testi tasarlanmıştır. İlk test, tam açık gaz kelebeği (WOT) koşullarında gerçekleştirilen bir hızlanma testidir. Bu test ile aracın ivmelenme sürecinde hangi frekans bantlarında maksimum ses basıncı oluştuğu analiz edilmiş ve odaklanılması gereken frekans aralığı belirlenmiştir. Bu aralık, çalışmanın ilerleyen bölümlerinde iyileştirme hedefi olarak esas alınmıştır.

İkinci yol testi ise, makine öğrenimi modelinin eğitimi için gerekli veri setini sağlamak amacıyla gerçekleştirilmiştir. Bu testte, farklı sürüş senaryoları ve yol koşulları altında 15 dakikadan uzun süreyle çoklu sensörler yardımıyla veri toplanmıştır. Elde edilen zaman serisi verileri daha sonra frekans alanına dönüştürülerek, model eğitimi ve değerlendirme süreçlerinde kullanılmıştır.

3.1 Test Metodunun Seçimi

Araç içi gürültü ve titreşim performansını değerlendirmeye yönelik testlerde, doğru veri toplama kadar uygun test metodolojisinin seçilmesi de kritik bir adımdır. Sinyal işleme sürecinin sağlıklı ilerleyebilmesi için, ölçüm koşullarının sistematik ve tutarlı biçimde yapılandırılması gerekir. Bu çalışmada, araç iç mekânında algılanan gürültünün seviyesini belirlemek ve iyileştirme stratejileri geliştirmek amacıyla özel olarak tasarlanmış bir test protokolü uygulanmıştır.

Bu kapsamda, aracın en zorlu dinamik yükleme durumu olan tam açık gaz kelebeği (WOT – wide open throttle) altında gerçekleştirilen hızlanma testi tercih edilmiştir. Bu test koşulu, güç aktarma organlarının maksimum tork üretmeye çalıştığı anları temsil eder ve bu nedenle gürültü kaynaklarının daha belirgin hale geldiği bir senaryodur. Motorun rölanti devrinden maksimum devrine kadar geniş bir çalışma aralığı taranabildiğinden, farklı devirlerdeki ses ve titreşim davranışlarının karşılaştırmalı olarak analiz edilmesine olanak sağlar.

Testin uygulanabilirliği ve veri çözünürlüğü açısından, vites seçimi büyük önem taşır. Alt viteslerde (1., 2. ve 3. vites), ivmelenme çok hızlı gerçekleştiği için ölçüm süresi kısa kalmakta; bu da önemli frekans bileşenlerinin, motor sıralarının ve tepe noktalarının zaman alanında yeterince ayrıştırılamamasına neden olmaktadır. Öte yandan, 5. vites gibi daha yüksek viteslerde ise araç yavaş ivmelenmekte, bu durum

veri kaydının gereksiz şekilde uzamasına, büyük veri dosyalarının oluşmasına ve rölanti devrinde aracın devir geçişlerinin stabil gerçekleşmesini zorlaştırmaktadır.

Bu nedenlerle, test sürecinde dördüncü vites optimum denge noktası olarak tercih edilmiştir. Bu vites, hem motor devir artışının yeterince yavaş gerçekleşmesini sağlayarak zaman çözünürlüğünü artırmakta hem de kritik frekanslardaki gürültü zirvelerinin güvenilir biçimde tespit edilmesine olanak tanımaktadır. Bu metodolojik yaklaşım, güç aktarma sistemiyle ilişkili GTS bileşenlerinin daha net biçimde ortaya konmasını sağlamış ve geliştirilecek iyileştirme hedeflerinin belirlenmesinde kritik rol oynamıştır.

3.2 Test Ortamı

Doğru ve güvenilir ölçüm verilerinin toplanmasında ölçüm tekniğinin yanı sıra ölçümlerin yapılacağı test ortamı da önemli rol oynamaktadır. Arka plan gürültü seviyesinin belirli değerlerin altında olması gerektiği açıktır (~0,5 dB ölçüm toleransına sahip olmak için araştırılan minimum seviyeden en az 10 dB daha düşük) [25], böylece ölçülecek gerçek araç gürültüsünü etkilemeyecektir. Test ortam gürültüsü yaklaşık 42 dB olarak ölçülmüştür.

Bu çalışmada aracın yol testleri sessiz bir güzergahta gerçekleştirilmiş olup test pisti etrafında en az 30 metre içerisinde yansıtıcı yüzey bulunmamaktadır. Test ortamı rüzgârsız olmasına rağmen araç dışında bulunan tüm mikrofonlar için rüzgâr kesici kullanılmıştır. Elde edilen ses verileri test sonrasında kulaklık ile dinlenerek araç gürültüsünü yansıtmayan seslerin olmadığı görülmüştür. Şekil 3.1'de araç yol testleri öncesindeki görüntüsü gösterilmiştir.



Şekil 3.1 Araç yol testleri

3.3 Veri Toplama Donanım ve Yazılımı

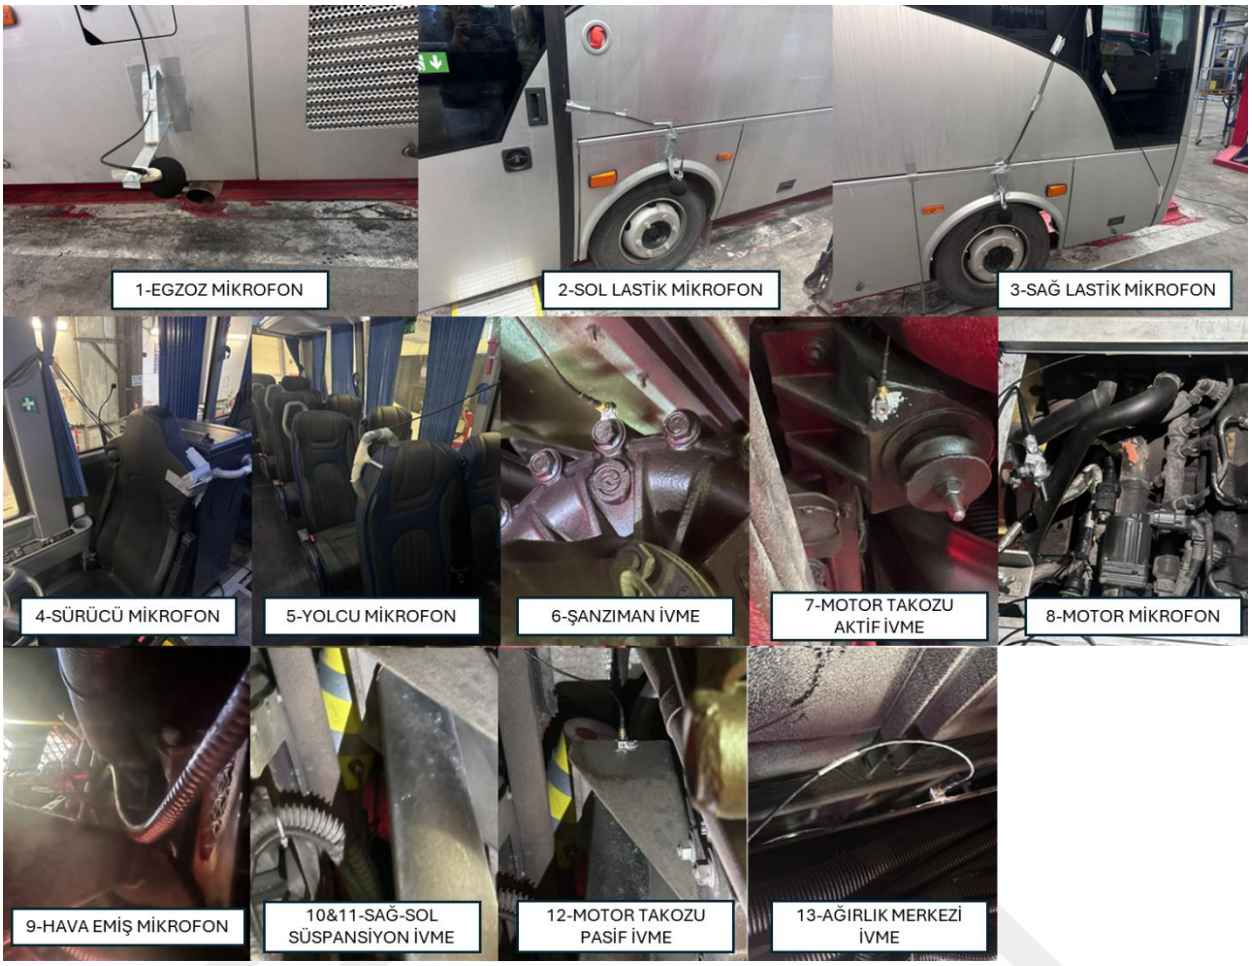
Araç içi gürültü ve titreşim karakteristiğini ortaya koymak amacıyla iki temel yol testi gerçekleştirilmiştir. Bu testlerin ilki, daha önce detaylandırıldığı üzere tam açık gaz kelebeği (WOT) altında uygulanan hızlanma testidir. İkinci test ise, aracın rastgele sürüş senaryoları altında çalıştırıldığı ve gerçek yol koşullarını temsil eden bir durumdur. Bu test kapsamında hem yapı kaynaklı titreşimler hem de hava kaynaklı ses bileşenleri detaylı biçimde analiz edilmiştir.

Şekil 3.1'de gösterildiği üzere, test sistemi, araç içi gürültüye katkı sağlayan başlıca kaynaklardan veri toplanacak şekilde yapılandırılmıştır. Bu amaçla araç üzerine toplam yedi adet mikrofon ve beş adet üç eksenli ivmeölçer yerleştirilmiştir. Mikrofonlar hem araç içindeki hem de dış bileşenlerden gelen hava kaynaklı sesleri tespit etmek için; ivmeölçerler ise yapı kaynaklı titreşimleri izlemek üzere kullanılmıştır. Sensör yerleşimi, motor bölmesi, hava emiş sistemi, egzoz hattı, lastik çevresi, şanzıman bölgesi, motor payandası ve şasi merkezi gibi kritik alanları kapsayacak şekilde planlanmıştır.

Veri toplama sistemi, bu sensörlerden gelen sinyallerin gerçek zamanlı olarak entegre edilmesini sağlayacak biçimde tasarlanmıştır. Yedi farklı mikrofondan elde edilen ses verileri ile her biri üç eksenli toplam beş ivmeölçerden elde edilen 15 eksenli titreşim verisi birleştirilmiş; böylece toplamda 22 ayrı sinyal kanalı eşzamanlı olarak kaydedilmiştir. Ölçüm hassasiyetinin korunması adına, mikrofonlar için 20.000 Hz, ivmeölçerler için ise 50.000 Hz örnekleme frekansı tercih edilmiştir. Bu yüksek örnekleme oranları, özellikle düşük frekanslı yapı kaynaklı titreşimlerle yüksek frekanslı hava kaynaklı ses bileşenlerinin detaylı analizine olanak sağlamıştır.

Ek olarak, sürüş sırasında iç mekân algısını değerlendirebilmek amacıyla, sürücü koltuğu hizasına ve araç içindeki önceden belirlenen orta koltuk pozisyonuna mikrofonlar yerleştirilmiştir. Bu mikrofonlar yardımıyla, yolculuk esnasında gerçek zamanlı olarak araç içi gürültü seviyelerindeki değişim kayıt altına alınmıştır.

Testte kullanılan mikrofon ve ivme sensörlerinin teknik özellikleri, Tablo 3.2'de ayrıntılı olarak sunulmuştur. Deneyde kullanılan aracın temel özellikleri ve sensör yerleşim bilgileri ise Tablo 3.1'de özetlenmiştir.



Şekil 3.2 Veri toplama için araçtaki sensör konumları

Tablo 3.1 Veri lokasyonlarına karşılık veri toplama cihazı adresleme kullanımı

	LOKASYONU	**VERİ ADRESLEME**
1	Egzoz Mikrofon	EGZOZ_MIC_dbA
2	Sol Lastik Mikrofon	SOL_LASTIK_MIC_dbA
3	Sağ Lastik Mikrofon	SAG_LASTIK_MIC_dbA
4	Sürücü Mikrofon	SURUCU_MIC_dbA
5	Yolcu Mikrofon	YOLCU_MIC_dbA
6	Şanzıman İvme	SANZIMANUSTG_Acc
7	Motor Takozu Akrif İvme	MOTORSOLAKTIFG_ACC
8	Motor Mikrofon	MOTOR_MIC_dbA
9	Hava Emiş Mikrofon	HAVA_EMIS_MIC_dbA
10	Sağ Süspansiyon İvme	SAGSUSPANSIYONG_ACC
11	Sol Süspansiyon İvme	SOLSUSPANSIYONG_ACC
12	Motor Takozu Pasif İvme	MOTORSOLPASIFG_ACC
13	Ağırlık Merkezi İvme	x_AS_USTG

Tablo 3.2 Testlerde kullanılan araç özellikleri

	Açıklama
Ağırlık	11480 kg
Motor	Silindir Sayısı 4 Motor Hacmi (cc) 4500 Maksimum Güç (kW(PS)/dd) 151 (205) / 2300 Maksimum Tork (Nm/dd) 832 nm / 1200-1450
Ön Süspansiyon	Parabolik Çelik Alaşımlı Yaprak Yaylar
Arka Süspansiyon	Havalı Süspansiyon

Tablo 3.2 Sensör özellikleri

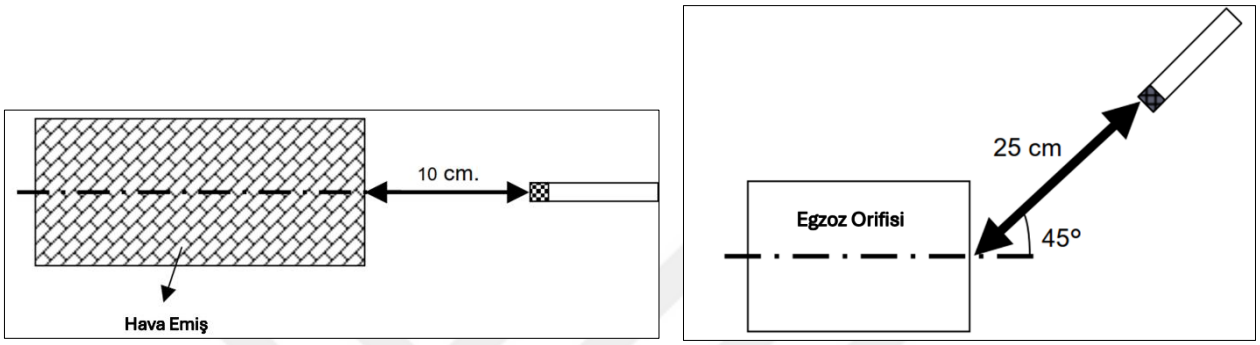
Sensör	Tip	Ölçüm Aralığı	Detaylı Açıklama
Mikrofon	378B02	3.75–20.000 Hz	1/2” ön polarize serbest alan kondansatör mikrofonu
İvmeölçer	356A15	2–5000 Hz	3 eksenli, yüksek hassasiyetli, seramik



(a) (b)

Şekil 3.3 Testlerde kullanılan sensörler (a) mikrofon; (b) ivmeölçer

Emme sisteminin yaydığı gürültü, emme orifisinin merkezinden 10 cm uzaklıkta ve dik açıyla yerleştirilen bir mikrofonla ölçülmüştür. Egzoz orifisinin yaydığı gürültü, merkez eksenden 45° açıyla ölçülmekte ve mikrofon, egzoz orifisinden 25 cm uzaklıkta konumlandırılmaktadır. Mikrofonun konumu, emme ölçümlerinde olduğu gibi daha yakın ve dik olarak ayarlanmamıştır; çünkü sıcak egzoz gazları mikrofon yapısına zarar verebilir. Yine, yüksek frekanslı hava akışı gürültüsünü ortadan kaldırmak için bir mikrofon rüzgâr koruyucusu kullanılmaktadır.



Şekil 3.4 Hava emiş ve egzoz orifisi mikrofon ölçüm konumları [21]

4
GÜRÜLTÜ TİTREŞİM TESTLERİ VE VERİ TAHMİN METODU

Bu bölümde, içten yanmalı motorlu büyük yolcu otobüsünün gürültü, titreşim ve sertlik (GTS) performansının değerlendirilmesine yönelik olarak gerçekleştirilen deneysel çalışmalara yer verilmiştir. Testler, hem araç içi akustik davranışın karakterize edilmesi hem de makine öğrenimi tabanlı modellemelere temel veri sağlanması amacıyla iki aşamalı olarak planlanmıştır.

Çalışmada gerçekleştirilen testler iki ana amaca hizmet etmektedir:

- Birinci Test – GTS İyileştirme Amaçlı Frekans Alanı Belirleme (WOT Testi): Bu test, aracın en yüksek uyarı altında (tam açık gaz kelebeği- WOT) maruz kaldığı iç gürültü karakteristiğini belirlemek amacıyla uygulanmıştır. Elde edilen spektral veriler yardımıyla, iç mekân akustik konforunu olumsuz etkileyen kritik frekans bantları belirlenmiş ve iyileştirme yapılması gereken hedef frekans aralığı tespit edilmiştir. Bu test, hedefe yönelik GTS

optimizasyon stratejilerinin belirlenmesi açısından kritik bir ön adımı oluşturmaktadır.

- İkinci Test – Makine Öğrenimi İçin Veri Seti Oluşturma (Rastgele Sürüş Testi): Farklı hız ve yol koşulları altında gerçekleştirilen rastgele sürüş senaryoları ile uzun süreli (15 dakikadan fazla) çoklu sensör verisi toplanmıştır. Bu veri, Rastgele Orman algoritması başta olmak üzere çeşitli makine öğrenimi modelleri için eğitici ve doğrulayıcı veri seti olarak kullanılmıştır. Bu yaklaşım sayesinde, manuel ve zaman alıcı geleneksel analiz yöntemlerine alternatif olarak, veri odaklı GTS tahmin modellerinin geliştirilmesi hedeflenmiştir.

Her iki testin içeriği, kullanılan ekipmanlar, test düzenekleri, uygulama metodolojisi ve elde edilen sonuçlar, takip eden alt başlıklarda detaylı olarak açıklanmıştır.

4.1 Sürüş Testi Verilerinin İncelenmesi

Araç içi gürültü ve titreşim davranışlarının doğru biçimde analiz edilebilmesi için, ses iletim yollarının ve uyarıcı kaynakların transfer fonksiyonlarının detaylı şekilde anlaşılması gerekmektedir. Özellikle karmaşık yapısal özelliklere sahip, çok sayıda rezonans moduna ve doğrusal olmayan dinamik bileşenlere sahip sistemlerde bu gereklilik daha da kritik hâle gelmektedir. GTS performansının etkin biçimde değerlendirilebilmesi, yalnızca sabit durum analizleriyle değil, aynı zamanda araç dinamiklerinin değiştiği senaryolardaki akustik tepkilerin de ayrıntılı şekilde incelenmesini zorunlu kılar.

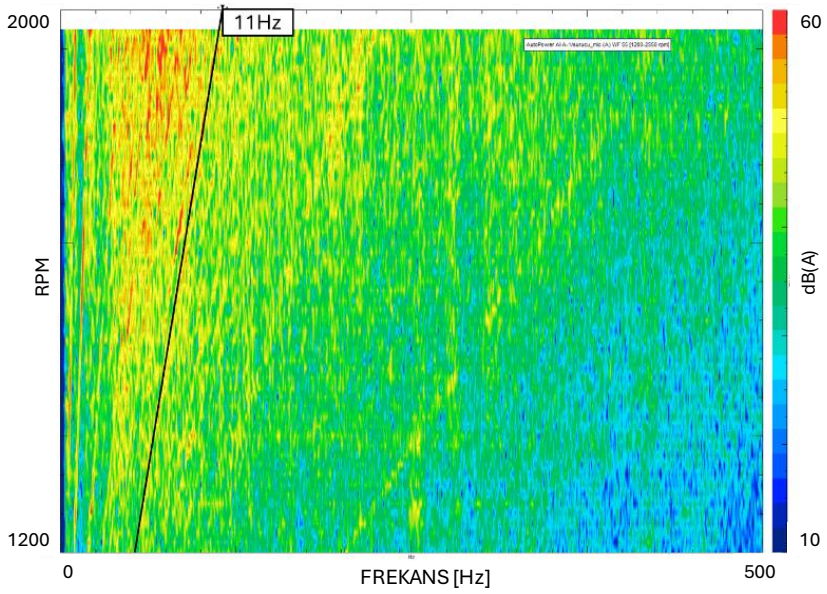
Bu bağlamda, hızlanma koşulları altındaki araç içi akustik tepkilerin anlaşılması için elde edilen veriler üzerinden oluşturulan Şekil 4.1'deki Waterfall (şelale) diyagramı, çok boyutlu bir spektral çözümleme sunmaktadır. Bu üç boyutlu görselleştirme; yatay eksende frekansı, dikey eksende ses basınç seviyesini (dBA) ve derinlik ekseninde ise motor devrini (RPM) göstererek zaman-frekans etkileşiminin anlaşılmasına olanak tanımaktadır. Test koşulu olarak tam açık gaz kelebeği (WOT) altında yapılan hızlanma testi seçilmiş, böylece güç aktarma organlarının en yoğun çalıştığı senaryodaki akustik davranışlar modellenmiştir.

Diyagramda kullanılan renk skalası, frekans bazlı ses yoğunluklarını görsel olarak ifade etmektedir. Kırmızı ve turuncu bölgeler, ilgili frekanslarda yüksek ses enerjisi birikimini; mavi ve yeşil tonlar ise daha düşük akustik etkinlik seviyelerini temsil eder. Özellikle yaklaşık 11 Hz çevresinde gözlemlenen yoğunluk artışı, bu çalışmada iyileştirme hedefi olarak seçilen frekans bandını işaret etmektedir.

Waterfall diyagramı, yalnızca frekans spektrumunun zamana göre değişimini göstermekle kalmayıp; GTS mühendisliğinde kritik rezonans noktalarının saptanması, baskın gürültü kaynaklarının izlenmesi ve modelleme yapılacak ana frekans bileşenlerinin belirlenmesi gibi çok yönlü analizlere temel oluşturmaktadır. Şekil 4.1 özelinde yapılan analiz, makine öğrenimi sürecinde kullanılacak olan hedef frekans bandının (11 Hz) belirlenmesinde yönlendirici olmuş, aynı zamanda sistematik veri ayrıştırma sürecinin ilk adımını oluşturmuştur.

Benzer şekilde, diğer mikrofon ve ivmeölçer verilerine ait waterfall grafiklerinin incelenmesi sonucunda, 11 Hz çevresinde benzer akustik yoğunlaşmaların gözlemlendiği tespit edilmiştir. Bu tutarlılık, ilgili frekans bandının sistematik bir gürültü bileşeni içerdiğini göstermekte ve kaynakların bu aralıkta yoğunlaştığını doğrulamaktadır.

Sonuç olarak, şelale diyagramı kullanılarak elde edilen bu görsel analiz, klasik frekans spektrumlarının ötesine geçen bir bakış açısı sunarak hem mühendislik kararlarının temellendirilmesi hem de makine öğrenimi modellerinin doğruluğunun artırılması için güçlü bir referans oluşturmuştur. Şekil 4.1'de siyah çizgiyle işaretlenen bölge, çalışmanın odaklandığı yüksek enerjiye sahip frekans alanını açıkça tanımlamaktadır.



Şekil 4.1 Hızlanma testi sırasında frekans alanındaki iç mekân gürültüsü

Bu çalışmada, makine öğrenmesi temelli modelleme süreci için gerekli veri setinin oluşturulması amacıyla, farklı sürüş koşullarını kapsayan rastgele sürüş testi uygulanmıştır. Test sırasında toplanan ses ve titreşim verileri, motor devri yaklaşık 800 ila 1800 RPM aralığındayken ve araç hızı 0 ila 60 km/sa arasında değişirken kayıt altına alınmıştır. Ölçümlerin dış çevresel faktörlerden etkilenmemesi için, özellikle rüzgâr gürültüsünün etkisini en aza indirmek amacıyla test boyunca araç hızı 80 km/sa'nin altında tutulmuştur.

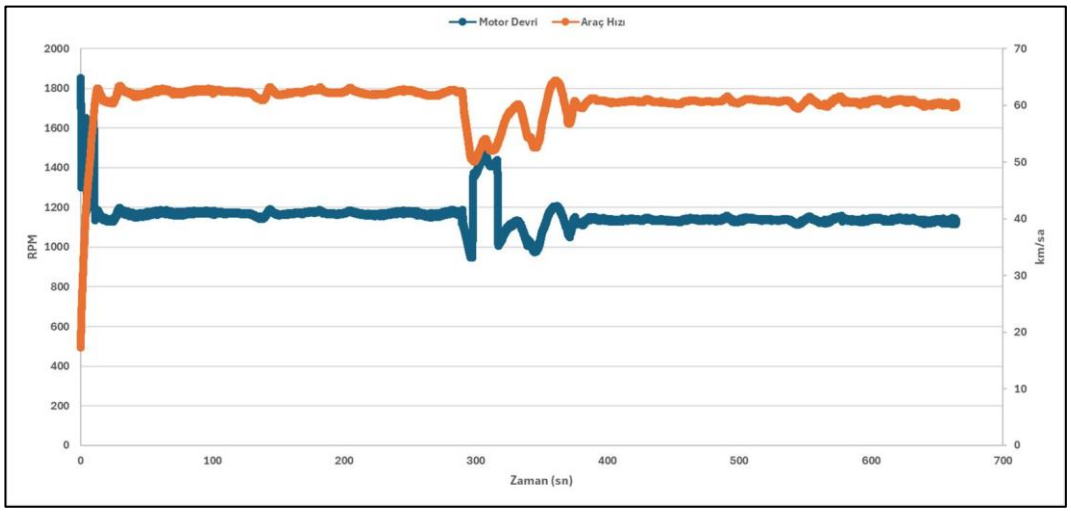
Tüm ölçüm çalışmaları, ANADOLU ISUZU Ar-Ge Merkezi'ne ait özel ve kontrollü bir test pistinde gerçekleştirilmiştir. Test altyapısının bu şekilde sınırlandırılması hem tekrar edilebilirlik hem de dışsal etkilerin kontrolü açısından önemli bir avantaj sağlamıştır.

Veri toplama sürecinde, aracın GTS karakteristiği üzerinde belirleyici etkisi olan iki temel uyarı kaynağı dikkate alınmıştır: güç aktarma organları ve yol yüzeyi etkileşimleri. Bu bağlamda, sensör konumlandırmaları, araç gövdesinde bu iki kaynaktan doğrudan etkilenebilecek kritik yapısal bölgeleri kapsayacak şekilde planlanmıştır. Ölçüm sistemi, motor bloğu, egzoz hattı, hava emiş sistemi ve lastikler gibi bileşenlere yerleştirilen mikrofonlardan; ayrıca motor bağlantı noktaları ve şasi üzerinde konumlandırılmış üç eksenli ivmeölçerlerden oluşmaktadır.

Verilerin analizinde odak noktası, frekans bazlı duyarlılık analizidir. Bu nedenle, veri toplama işlemi özel olarak rastgele sürüş koşulları altında yürütülmüş; böylece

araç kullanımında karşılaşılabilecek farklı dinamik yükleme senaryolarının doğal biçimde temsili sağlanmıştır. Bu yaklaşım, makine öğrenimi algoritmalarının daha genelleştirilebilir sonuçlar üretmesini mümkün kılmaktadır.

Toplanan veriler, zaman alanından frekans alanına dönüştürülmek üzere uygun ön işleme adımlarına tabi tutulmuş ve analiz için hazırlanmıştır. Şekil 4.2, test sırasında elde edilen motor devri ve araç hız değerlerinin zamana bağlı değişimini grafiksel olarak göstermektedir. Bu grafik, test sürecinin sürekliliğini ve ölçümlerin hangi sürüş aralıklarında yoğunlaştığını görsel olarak özetlemektedir.



Şekil 4.2 Rastgele sürüş koşullarında RPM ve araç hızı verisi

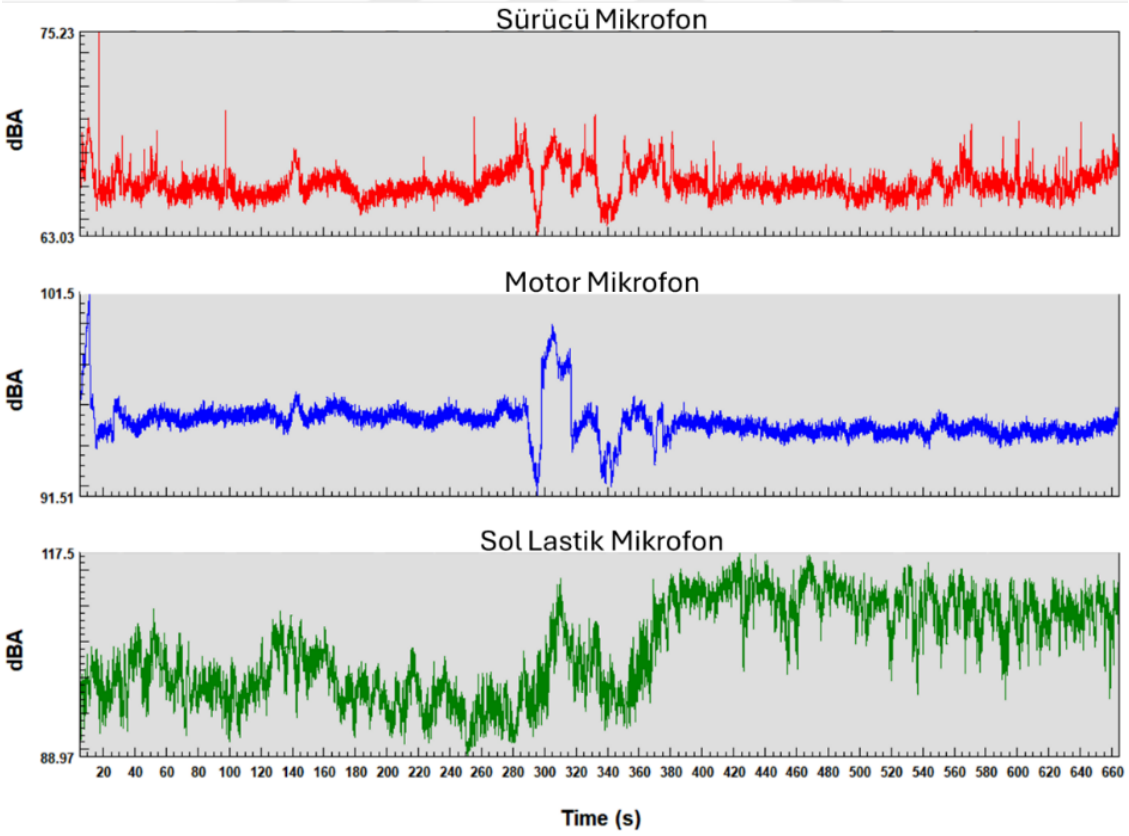
Analiz süreci, sensör sistemlerinden elde edilen ham verilerin zaman alanında kaydedilmesiyle başlatılmıştır. Bu ham veriler, öncelikle istatistiksel önişleme adımlarından geçirilmiştir. Bu kapsamda eksik kayıtlar, gürültülü ölçümler ve aykırı değerler ayıklanarak veri seti temizlenmiş, ardından frekans alanına dönüştürme işlemi için uygun hale getirilmiştir. Zaman serisi verileri, daha sonra Hızlı Fourier Dönüşümü (HFD) uygulanarak frekans alanına aktarılmış ve analizlerin büyük bir bölümü bu dönüştürülmüş veriler üzerinden yürütülmüştür.

Sadece tek yönlü uyarı–yanıt ilişkileriyle sınırlı kalmamak ve sistemin karmaşık dinamik davranışını daha gerçekçi biçimde temsil edebilmek amacıyla, veri toplama süreci farklı sürüş koşullarını kapsayacak şekilde yapılandırılmıştır. Bu strateji doğrultusunda, değişken yol yüzeyleri ve çeşitli araç hızları altında gerçekleştirilen sürüşlerde; güç aktarma organlarından kaynaklanan titreşim ve gürültüler, süspansiyon sisteminden gelen yapısal titreşimler, hava emiş ve egzoz

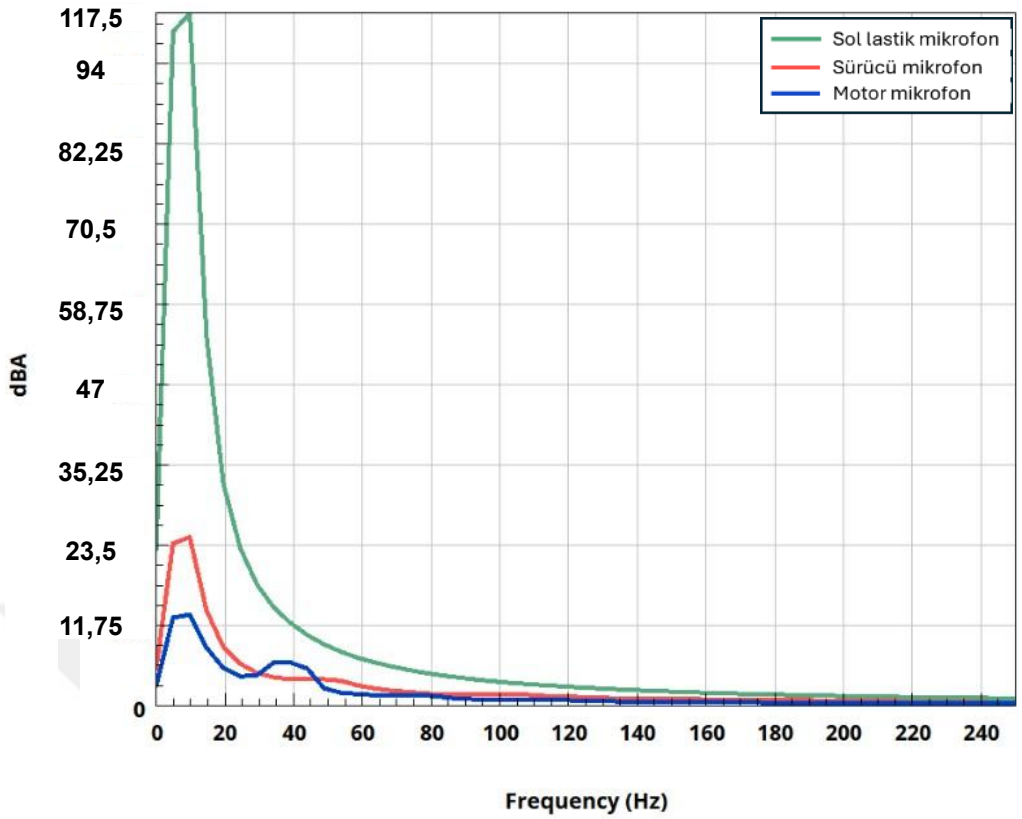
sistemlerinin ses emisyonları ile lastik temas kaynaklı akustik girdiler izlenmiştir. Bu uyarım kaynaklarına karşılık gelen hedef değişkenler ise, araç iç mekânında algılanan ses basınç seviyeleri ve titreşim verileri olmuştur.

Veri toplama işlemi, her biri 15 dakikayı aşkın sürede gerçekleştirilen rastgele sürüş senaryoları altında, çok kanallı bir ölçüm sistemi kullanılarak yürütülmüştür. Bu ölçümler hem uyarım noktalarına hem de iç mekân hedef konumlarına ilişkin geniş ve zengin bir veri kümesi elde edilmesini sağlamıştır. Frekans bazlı duyarlılık analizleri de bu veri seti üzerinden gerçekleştirilmiş, böylece sistemin farklı uyarıcılara verdiği tepkiler spektral bağlamda analiz edilebilmiştir.

Yürütülen analizlerin daha iyi anlaşılabilmesi adına, örnek olarak üç farklı konumda yer alan mikrofonlardan elde edilen ses seviyelerine ilişkin zaman serisi verileri Şekil 4.3'te sunulmuştur. Bu grafikler, sürüş boyunca frekans alanında ortaya çıkan farklı karakteristikleri görsel olarak yansıtmakta ve uyarım-hedef ilişkilerinin yorumlanmasına katkı sağlamaktadır.



Şekil 4.3 Rastgele sürüş koşullarında zamana bağlı mikrofon verileri



Şekil 4.4 Rastgele sürüş koşullarında frekansa bağlı mikrofon verileri

Veri analizinin temelini, her bir uyarım kaynağı ile hedef konum arasında gerçekleştirilen frekans temelli çözümlemeler oluşturmaktadır. Bu amaçla, zaman alanında kaydedilen tüm sensör verileri, önişleme adımlarının ardından Hızlı Fourier Dönüşümü (HFD) yöntemi ile frekans alanına aktarılmıştır. Analiz sürecine yalnızca sinyal açısından anlamlı ve temiz veri parçaları dahil edilmiştir. Böylece, sistem dışı etkileşimlerin ve gürültü bileşenlerinin baskılanması sağlanmış, elde edilen spektrumların bütünlüğü ve doğruluğu artırılmıştır.

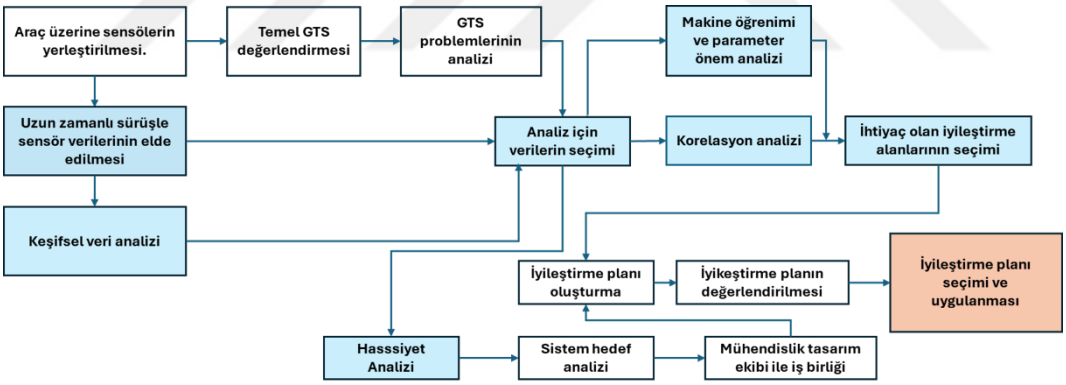
Uygulanan önişleme stratejisi, frekans-temelli spektral analizlerde yaygın olarak kullanılan ve literatürde özellikle derin öğrenme tabanlı NVH modelleme çalışmalarıyla benzerlik gösteren bir yöntemle uyumludur [26]. Bu yaklaşım sayesinde, elde edilen veriler hem homojen bir yapıya kavuşturulmuş hem de modelleme süreci için daha güvenilir bir veri tabanı oluşturulmuştur.

Frekans dönüşümü sonucunda elde edilen spektrumlar, araç içindeki farklı konumlara yerleştirilen üç mikrofonun ölçümleri üzerinden Şekil 4.4'te görsel olarak sunulmuştur. Bu grafikler, belirli frekans aralıklarında ses enerjisinin nasıl yoğunlaştığını ve frekans dağılımının karakteristik davranışlarını ayrıntılı biçimde

ortaya koymaktadır. Görselleştirme, akustik tepkinin yalnızca genlik seviyeleriyle değil, aynı zamanda hangi konumlarda ve frekanslarda baskın hale geldiğiyle ilgili mühendislik analizlerine temel teşkil etmektedir.

Spektral veriler üzerinden, her bir uyarım kaynağı ile hedef arasında korelasyon katsayıları hesaplanmıştır. Bu hesaplamalar, kaynak-hedef ilişkilerinin istatistiksel temelde değerlendirilmesini sağlamış; ayrıca, belirli frekans bantlarında hangi kaynakların iç mekânda daha baskın etkiler yarattığını belirlemek amacıyla duyarlılık sıralaması (sensitivity ranking) analizi gerçekleştirilmiştir. Söz konusu analiz, yalnızca korelasyona dayalı ilişkileri değil; aynı zamanda kaynak sinyalindeki değişimlerin hedef sinyal üzerindeki etkisini nicel biçimde tanımlayan bir sistem yaklaşımı sunmaktadır.

Tez kapsamında geliştirilen tüm analiz adımları, Şekil 4.5'te sunulan akış şeması ile sistematik olarak özetlenmiştir. Bu şema, veri toplama sürecinden başlayarak, önişleme, frekans dönüşümü, modelleme ve değerlendirme basamaklarına kadar tüm süreçleri görsel bir düzen içinde ortaya koymakta ve geliştirilen yöntemin bütüncül yapısını desteklemektedir.



Şekil 4.5 Sürüş verilerine dayalı GTS analiz akış şeması

4.2 Frekans Temelli Filtreleme Yaklaşımı

Bu çalışmada, test verilerinin spektral analizi sonucunda araç içi koltuk bölgesi gürültüsünün belirgin şekilde arttığı 11 Hz frekans bandı, değerlendirme ve modelleme açısından odak noktası olarak belirlenmiştir. Literatürde iç mekân gürültüsüne neden olan frekanslar araç tipine göre değişmekle birlikte, bu çalışmada deneysel olarak elde edilen spektral yoğunluk sonuçları, özellikle 11 Hz bandında öne çıkan bir rezonans davranışına işaret etmiştir. Bu nedenle, tüm

frekans-temelli analiz ve makine öğrenimi uygulamaları bu hedef frekansa odaklanacak şekilde yapılandırılmıştır.

Zaman alanında elde edilen ivme ve ses verilerinin doğrudan kullanılması, farklı frekans bileşenlerinin üst üste binmesinden dolayı sağlıklı bir frekans-spesifik analiz yapılmasına izin vermemektedir. Bu nedenle, makine öğrenimi modellerine giriş verisi oluşturulmadan önce, veriler belirli bir frekans bandına filtrelenerek dönüştürülmüştür.

Bu amaçla her bir sinyal için, öncelikle Hızlı Fourier Dönüşümü (FFT) uygulanarak zaman serileri frekans alanına taşınmıştır. Bu dönüşümle, her sensörden elde edilen sinyallerin spektral içeriği ayrıştırılmış ve 0–100 Hz aralığındaki bileşenler elde edilmiştir. Sonrasında, yalnızca 11 Hz merkez frekans etrafındaki ±1 Hz'lik bir aralık (yani 10–12 Hz bandı) hedeflenerek bu bölgedeki frekans bileşenleri band geçiren filtreleme yöntemi ile izole edilmiştir. Bu adım, sinyalin yalnızca istenilen frekans aralığına karşılık gelen kısmının analiz edilmesini sağlamıştır.

Filtreleme işlemi, dijital sinyal işleme prensiplerine uygun olarak, dijital band geçiren filtre (örneğin FIR tabanlı) veya spektral pencereleme yoluyla gerçekleştirilmiştir. Filtreleme sonrası, bu frekans bandındaki veriler, hem istatistiksel analiz (korelasyon, duyarlılık, değişken önem sıralaması) hem de makine öğrenimi modellemesi için giriş verisi olarak kullanılmıştır. Model, yalnızca bu frekans bandında yer alan enerjiyi öğrenmiş; sonuç olarak geliştirilen tahmin algoritmaları, yalnızca 11 Hz frekans bandına özgü tahmin sonuçları üretmiştir. Böylece, modelin çıktıları herhangi bir frekans genellemesi içermemekte, yalnızca belirlenen hedef frekansa odaklanmaktadır.

Bu yöntem sayesinde, klasik GTS analizlerinde sıklıkla karşılaşılan "frekanslar arası örtüşme" problemi önlenmiş ve her bir kaynağın 11 Hz bandındaki katkısı izole, karşılaştırılabilir ve yorumlanabilir hale getirilmiştir. Ayrıca bu yaklaşım, belirli bir frekans için mühendislik açısından hedefli iyileştirme önerileri geliştirilmesine olanak sağlamıştır.

4.3 Keşifsel Veri Analizi

Keşifsel Veri Analizi (KVA), ilk kez 1977 yılında John Tukey tarafından literatüre kazandırılmış olup, verilerin temel yapısını ve aralarındaki ilişkileri görselleştirme yoluyla anlamayı amaçlayan bir analiz yaklaşımıdır [27]. Analiz sürecinde ilk adım, veri kümesinin genel yapısını çeşitli grafiksel yöntemlerle inceleyerek değerlendirmektir. Özellikle, verilerin Gauss (normal) dağılımına uygunluğunun kontrol edilmesi; modelleme aşamasına geçmeden önce sinyal kalitesinin ve istatistiksel geçerliliğin sağlanması açısından önemlidir [28].

Bu doğrultuda, eğer veriler beklenen dağılım yapısından sapma gösteriyorsa veya standart dışı örüntüler içeriyorsa, ilgili veri parçaları filtrelenir ya da modellemeye dâhil edilmez. Bu çalışmada, analiz işlemleri MATLAB ortamında gerçekleştirilmiş; sinyaller üzerinde uygulanan önişleme süreci ile aykırı değerler tespit edilerek ayıklanmış ve analiz için yalnızca anlamlı veriler kullanıma alınmıştır.

Araçtan elde edilen gürültü ve titreşim verileri, sürekli uzun süreli sürüşler sırasında çok kanallı sensörler yardımıyla toplanmış; ardından zaman alanındaki sinyaller frekans alanına dönüştürülerek analiz edilmiştir. Gürültü, titreşim ve sertlik (GTS) parametrelerine yönelik sorunların çözümü için istatistiksel yöntemlerin yanı sıra makine öğrenmesi tekniklerinden de yararlanılmıştır. İyileştirme gerektiren alanlar, korelasyon ve parametre önem analizleriyle belirlenmiş; devamında duyarlılık ve sistem hedef analizleri gerçekleştirilerek, öneri geliştirme süreci yapılandırılmıştır.

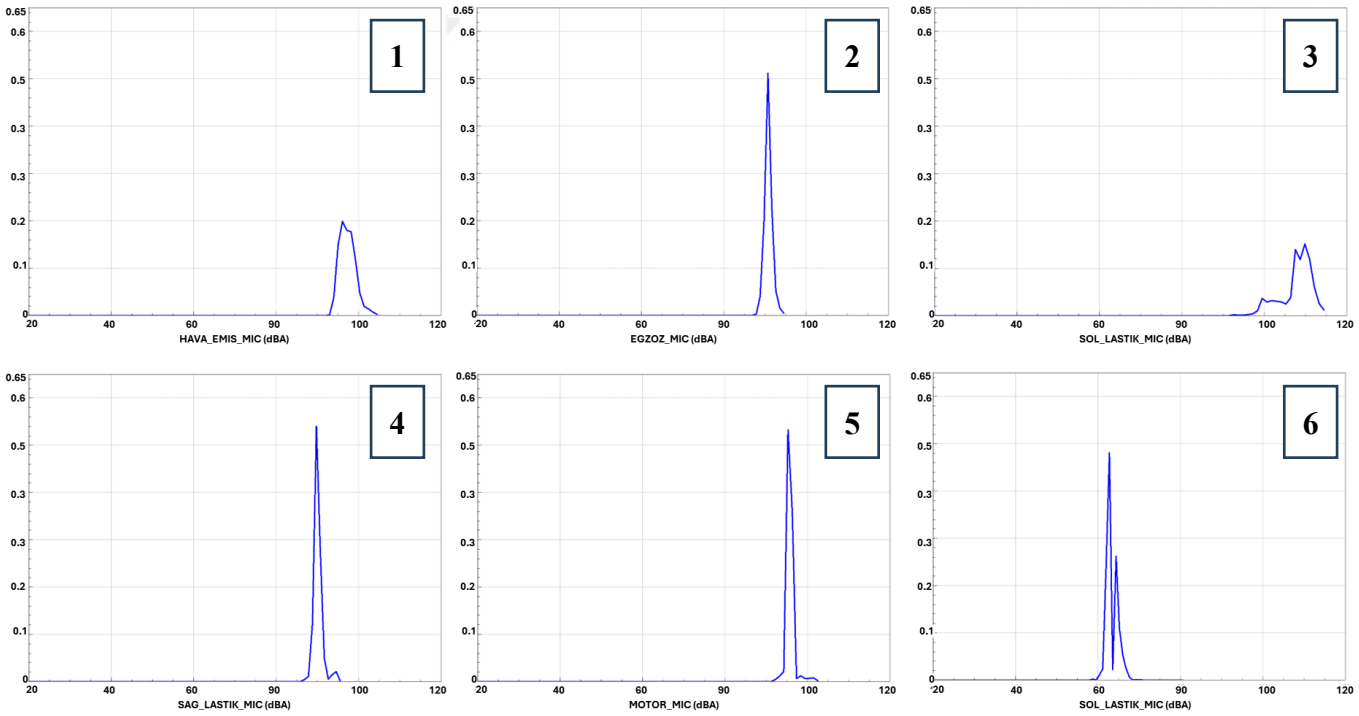
Veri kümesinin genel istatistiksel yapısını anlamaya yönelik olarak, iç mekân gürültüsü ve ivme verilerine ait Olasılık Yoğunluk Fonksiyonu (OYF / PDF) analizleri yapılmıştır. Bu analizler sayesinde, sinyallerin istatistiksel dağılım özellikleri, aykırı değerlerin varlığı ve modellemeye uygunluk düzeyi önceden değerlendirilmiştir. Şekil 4.6'da sunulan grafiklerde, örnek ivme ve ses sinyallerine ait olasılık yoğunlukları görselleştirilmiştir.

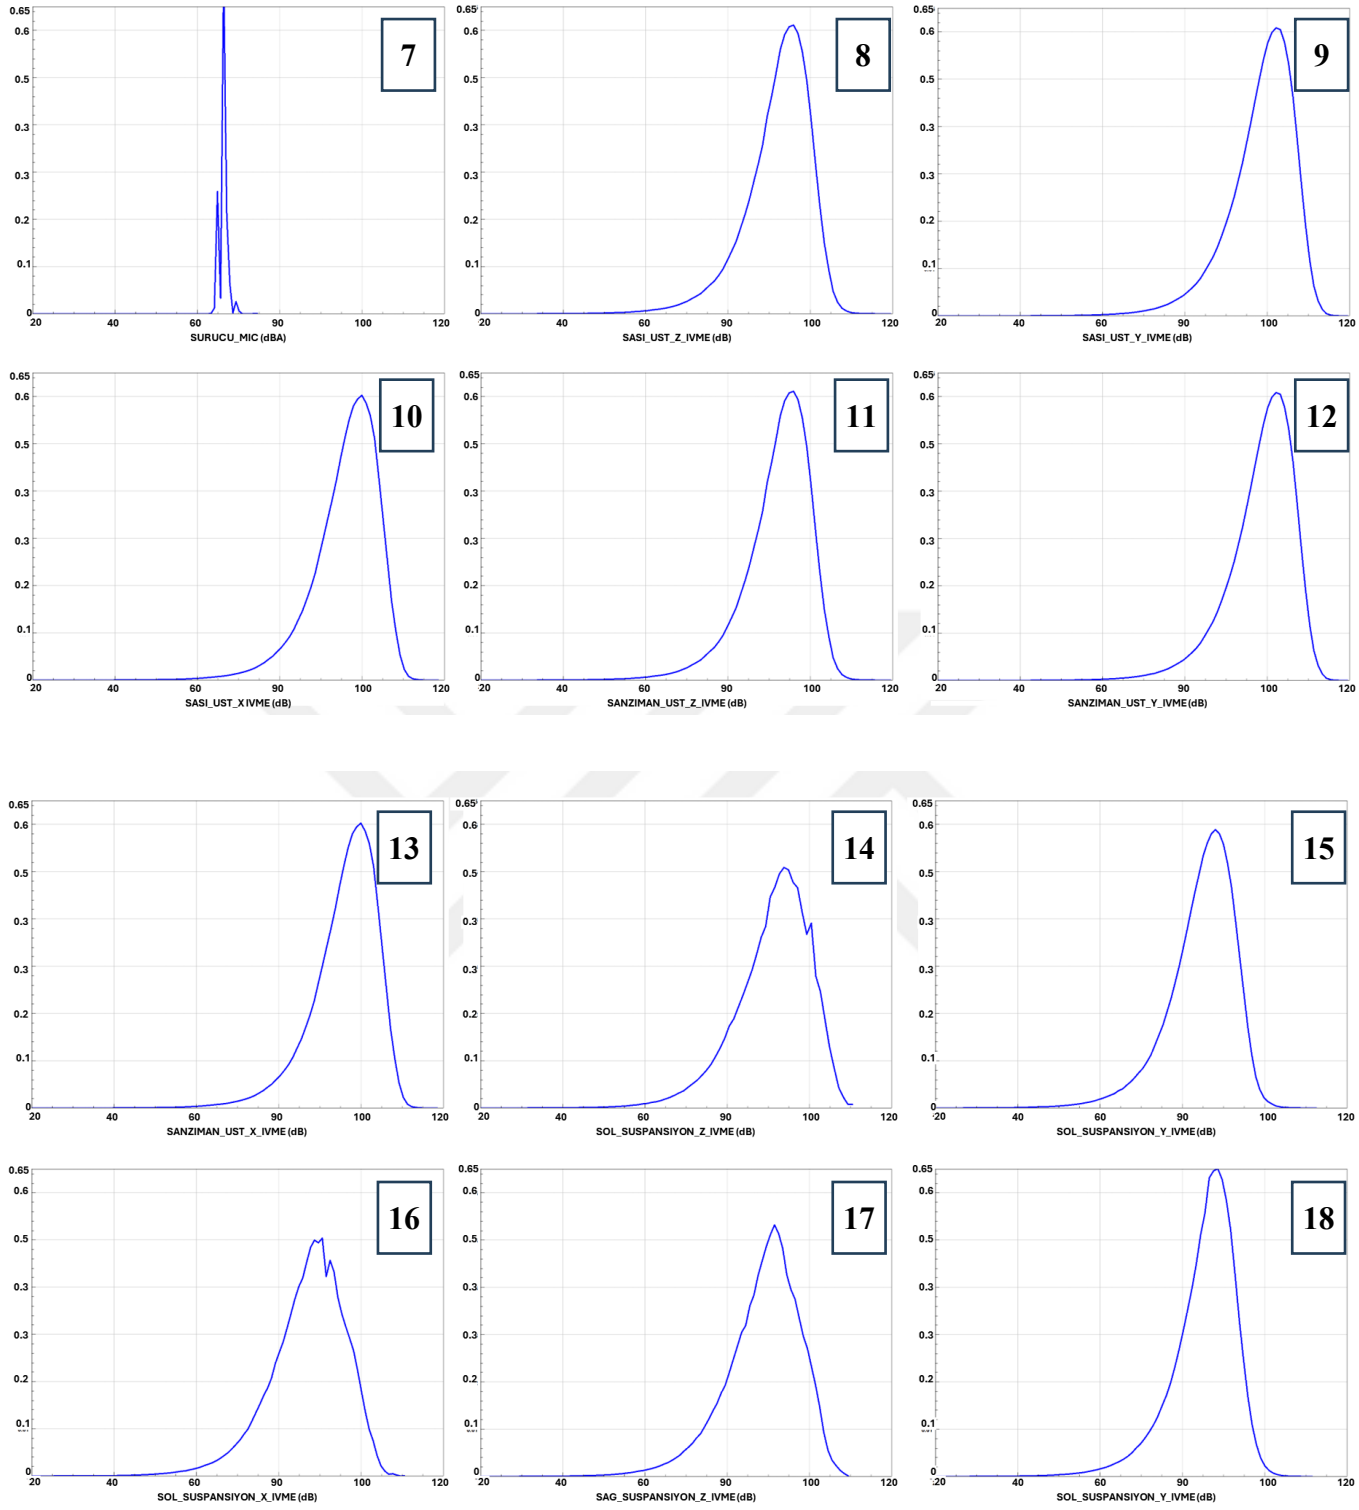
İvme verilerine ait grafikler incelendiğinde, verilerin çoğunlukla simetrik ve çan eğrisi benzeri bir dağılım sergilediği, dolayısıyla normal dağılıma yakınsadığı gözlemlenmiştir. Bu durum, yapısal titreşimlerin zaman içerisinde dengeli şekilde dağıldığını ve analiz açısından istatistiksel olarak uygun bir yapı oluşturduğunu göstermektedir. Öte yandan, gürültü sinyallerinde zaman zaman pozitif yönde

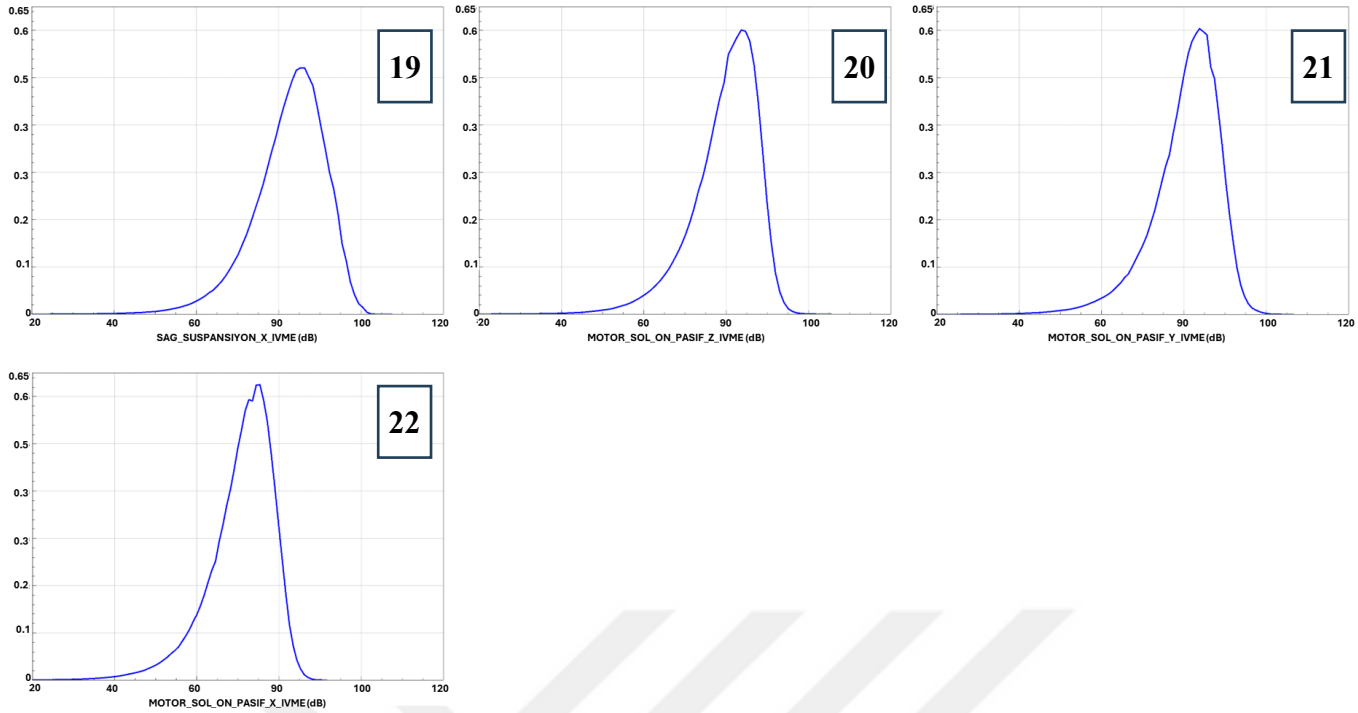
çarpıklık (skewness) tespit edilmiştir (örneğin Şekil 4.6'daki 3, 6 ve 7 numaralı grafiklerde). Bu çarpıklıklar, özellikle motor yüklenmeleri, vites değişimleri gibi ani ve kısa süreli akustik dalgalanmalarla ilişkilendirilmiştir.

Yoğunluk dağılımı analizleri sonucunda, varyans, ortalama, z-skoru ve standart sapma gibi temel istatistiksel ölçütler hesaplanmış; yüksek varyans ve sapma gösteren bazı sinyaller aykırı veri (outlier) olarak tanımlanarak modelleme dışında bırakılmıştır. Örneğin, ağırlık merkezi ve şanzıman bölgesine ait bazı ivme verileri, yüksek varyans ve z-skor değerleri nedeniyle modelde kullanılmamıştır. Bu şekilde oluşturulan temiz ve homojen veri seti, makine öğrenimi modelinin daha kararlı ve doğru sonuçlar üretmesini sağlamıştır.

Sonuç olarak, olasılık yoğunluk fonksiyonu analizleri hem veri temizliğini sağlamakta hem de modelleme öncesinde istatistiksel uygunluk açısından bir kontrol mekanizması işlevi görmektedir. Bu süreç sayesinde model doğruluğu %79'dan %84'e çıkarılmış ve güvenilir, öngörülebilir tahmin sistemlerinin geliştirilmesine katkı sağlanmıştır.




7
SURUCU_MIC (dBA)
8
SASI_UST_Z_IVME (dB)
9
SASI_UST_Y_IVME (dB)
10
SASI_UST_X IVME (dB)
11
SANZIMAN_UST_Z_IVME (dB)
12
SANZIMAN_UST_Y_IVME (dB)
13
SANZIMAN_UST_X_IVME (dB)
14
SOL_SUSPANSIYON_Z_IVME (dB)
15
SOL_SUSPANSIYON_Y_IVME (dB)
16
SOL_SUSPANSIYON_X_IVME (dB)
17
SAG_SUSPANSIYON_Z_IVME (dB)
18
SOL_SUSPANSIYON_Y_IVME (dB)



Şekil 4.6 Değişkenlerin yoğunluk dağılımı (11 Hz Bandı)

Tablo 4.1 GTS verilerinin istatistik hesaplamaları

	VERI	VARYANS	ORTALAMA Z-SKOR
1	MOTOR SOL ON PASIF XG (Acc)	0.005	0
2	MOTOR SOL ON PASIF YG (Acc)	0.087	0
3	MOTOR SOL ON PASIF ZG (Acc)	0.037	0
4	SAG SUSPANSIYON XG (Acc)	0.074	0
5	SAG SUSPANSIYON YG (Acc)	0.13	0
6	SAG SUSPANSIYON ZG (Acc)	0.321	0
7	SOL SUSPANSIYON XG (Acc)	0.232	0
8	SOL SUSPANSIYON YG (Acc)	0.125	0
9	SOL SUSPANSIYON ZG (Acc)	0.55	0
10	SANZIMAN UST XG (Acc)	1.503	0.54
11	SANZIMAN UST YG (Acc)	2.678	1.35
12	SANZIMAN UST ZG (Acc)	0.687	0.19
13	SASI UST XG (Acc)	1.503	0.62
14	SASI UST YG (Acc)	2.678	1.6
15	SASI UST ZG (Acc)	0.687	1.02
16	YOLCU_MIC (dBA)	1.763	0
17	MOTOR_MIC (dBA)	1.074	0

18	SOL_LASTIK_MIC (dBA)	1.57	0
19	SAG_LASTIK_MIC (dBA)	1.39	0
20	EGZOZ_MIC (dBA)	1.078	0
21	HAVA_EMIS_MIC (dBA)	1.96	0
22	SURUCU_MIC (dBA)	0.864	0

İvme verilerine ilişkin olasılık yoğunluk fonksiyonları incelendiğinde, bu sinyallerin büyük oranda simetrik ve çan eğrisi formunda dağıldığı gözlemlenmiştir. Bu durum, verilerin yaklaşık olarak normal (Gauss) dağılımı sergilediğini ve yapısal titreşimlerin zaman içerisinde dengeli bir şekilde yayıldığını göstermektedir. Elde edilen bu sonuç, ilgili titreşim bileşenlerinin modelleme süreçlerinde istatistiksel olarak anlamlı ve öngörülebilir bir yapı sunduğuna işaret etmektedir.

Buna karşılık, araç içi gürültü verilerinin dağılımı zaman zaman pozitif yönde çarpıklık (skewness) göstermektedir. Özellikle motorun yük altında çalıştığı anlar veya vites geçişleri gibi ani akustik değişimlerin yaşandığı durumlarda, kısa süreli fakat yüksek enerjili sinyal artışları meydana gelmiştir. Bu çarpıklık, sistemdeki ani ve geçici uyarım durumlarının veriye yansıması olarak değerlendirilmiş; bu bağlamda iyileştirme stratejilerinin planlanmasında dikkate alınması gereken önemli bir dinamik olarak tanımlanmıştır.

Yapılan dağılım analizleri sayesinde veri setine ait temel istatistiksel parametreler olan varyans, ortalama z-skoru ve standart sapma gibi ölçütler hesaplanmış; bu veriler üzerinden aykırı değer (outlier) tespiti gerçekleştirilmiştir. Yüksek varyansa sahip ve normal dağılımdan anlamlı düzeyde sapan sinyaller, önişleme sürecinde ayıklanarak modelleme dışında tutulmuştur. Örneğin, ağırlık merkezi ve şanzıman bölgesinde konumlandırılmış ivmeölçerlerden alınan bazı sinyaller, yüksek z-skor değerleri nedeniyle dışlanmış ve modelin istatistiksel homojenliği korunmuştur.

Sonuç olarak, OYF analizleri, yalnızca veri temizliği açısından değil; aynı zamanda modelleme öncesi güvenilirliğin ve doğruluğun artırılmasında da temel bir rol oynamıştır. Verilerin genel olarak normal dağılıma yakınsadığı doğrulanmış; bu sayede makine öğrenmesi modelinin doğruluk oranı %79'dan %84'e yükseltilmiştir. Bu aşama, çalışmanın veri bilimi tabanlı mühendislik sürecinde sağlam ve tutarlı tahmin modellerinin inşa edilmesine doğrudan katkı sağlamıştır.

4.4 Makine Öğrenimi Kullanarak Değişken Önem Analizi

Tam ölçekli modelleme aşamasına geçmeden önce, elde edilen veri seti üzerinde özellik önem düzeylerini belirlemek amacıyla modern bir veri madenciliği yöntemi olan Rastgele Orman (Random Forest) algoritması uygulanmıştır. Bu yöntem, hedef değişkenlerle (örneğin araç içi ses seviyeleri) girdi değişkenleri (motor, egzoz, süspansiyon vb. kaynaklardan gelen titreşim ve ses verileri) arasındaki ilişkilerin istatistiksel önemini ortaya koymak amacıyla kullanılmıştır [30, 31].

Rastgele Orman, temelinde birçok karar ağacının oluşturduğu bir topluluk öğrenme (ensemble learning) yaklaşımıdır. Her bir karar ağacı, eğitim verisinin farklı alt örneklerinden rastgele seçilerek eğitilir ve modelin her bir ağacı, tüm özellikler yerine farklı özellik alt kümeleri üzerinde çalışır. Bu yapı, modelin genelleme yeteneğini önemli ölçüde artırırken, aynı zamanda aşırı öğrenme (overfitting) riskini azaltır. Sonuç olarak hem daha kararlı hem de daha doğru tahminler elde edilmesi mümkün hâle gelir.

Rastgele Orman algoritması, özellikle GTS (Gürültü, Titreşim, Sertlik) gibi karmaşık, çok değişkenli ve doğrusal olmayan veri yapılarında yüksek başarıyla uygulanabilir. Bu yönüyle, GTS verilerinin tahmin edilmesinde tercih edilmesi yalnızca algoritmanın istatistiksel performansı açısından değil, mühendislik kararlarının güvenilirliğini artırması bakımından da kritik öneme sahiptir.

- GTS verileri genellikle karmaşık ve çok faktörlüdür; gürültü, titreşim ve sertlik gibi farklı parametrelerin bir arada analiz edilmesi gerekir. Rastgele Orman, bu çeşitlilik ve karmaşıklıkla başa çıkabilir.

Rastgele Orman, doğal olarak veri (değişken) seçimi yapabilen bir yöntemdir. Model, her bir karar ağacında hangi özelliklerin daha önemli olduğunu belirleyerek, gereksiz verileri dışarıda bırakır ve en fazla katkıyı sağlayanları seçer.

- GTS verileri, genellikle çok sayıda ölçüm ve değişkenden oluşur, bu yüzden hangi parametrelerin daha önemli olduğunu belirlemek önemlidir. Rastgele Orman, bu tür veri setlerinde önemli özellikleri ayırt etmede çok etkilidir.
- GTS verileri genellikle gürültülü olabilir ve çeşitli çevresel faktörlerden etkilenebilir. Rastgele Orman, bireysel karar ağaçlarındaki hataları telafi

ederek daha doğru tahminler yapar. Bu sayede model, veri setindeki gürültü ve hatalardan etkilenmeden doğru sonuçlar üretir.

- GTS verileri, sıklıkla hatalı veya eksik ölçümler içerebilir. Rastgele Orman, ağaçlar arasındaki çeşitlilik sayesinde, eksik veya hatalı verilerle başa çıkmada güçlüdür.

GTS verileri arasında sıklıkla lineer olmayan ilişkiler bulunur. Rastgele Orman, bu tür karmaşık ve non-lineer ilişkileri modelleyebilme yeteneğine sahiptir. Her bir ağaç, verinin farklı alt kümesi üzerinde çalıştığı için, model veri içindeki karmaşık yapıları öğrenebilir.

- GTS verileri çoğu zaman lineer olmayan ilişkilere dayanır. Örneğin, motor gürültüsü ile araç hızının, titreşim seviyesinin veya yol koşullarının etkileşimi lineer olmayabilir. Rastgele Orman bu tür ilişkilere daha iyi uyum sağlar.

Ratgele Orman, karar ağaçlarının birleşiminden oluştuğu için, her bir karar ağacını inceleyerek modelin nasıl çalıştığı hakkında bir fikir edinmek mümkündür. Ayrıca, verilerin önem derecelerini inceleyerek, hangi parametrelerin daha etkili olduğunu kolayca hesap edebilir.

- GTS uygulamalarında, hangi faktörlerin en fazla etkiye sahip olduğunu belirlemek önemlidir. Ratgele Orman, bu tür analizleri kolaylaştırarak, modelin doğruluğunun yanı sıra, araç iyileştirme kararları için faydalı bilgiler sağlar.

Ratgele Orman, çoğu zaman parametrik ayarlara ihtiyaç duymaz ve modelin genel performansı, büyük ölçüde ağaç sayısının ve maksimum derinliğin ayarlarıyla şekillenir. Bu, modelin eğitilmesi sırasında daha az müdahale gerektirir ve modelin hızlı bir şekilde uygulanmasını sağlar.

- GTS verilerinin analizi zaman alıcı olabilir. Ratgele Orman, modelin hızlıca oluşturulmasına ve yüksek doğrulukla tahminler yapılmasına olanak tanır, bu da araç geliştirme ve optimizasyon süreçlerinde verimlilik sağlar.

Ratgele Orman, her bir ağacı farklı veri alt kümeleri ve özellik alt kümeleriyle eğittiği için aşırı öğrenme riskini azaltır. Bu, modelin test verileri üzerinde daha iyi performans göstermesini sağlar.

- GTS tahminlerinde genellikle sınırlı sayıda örnek olabilir. Ratgele Orman, bu sınırlı veri setiyle bile etkili sonuçlar elde etmenizi sağlar çünkü her bir ağaç farklı veri alt kümeleri üzerinde eğitildiğinden, aşırı uyumdan kaçınılır.

GTS verilerinin tahmin edilmesi genellikle bir regresyon problemidir (örneğin, gürültü seviyesinin tahmin edilmesi). Ratgele Orman, regresyon sorunları için de son derece uygundur. Ayrıca, birden fazla çıktı ile çalışırken de iyi performans gösterir (çoklu hedefli tahminler).

GTS verileri genellikle çoklu parametrelerle ilişkilidir ve bu nedenle Rastgele Orman, farklı hedef değişkenlerin tahminini tek bir modelde yapabilir. Örneğin, gürültü ve titreşim seviyesi aynı anda tahmin edilebilir.

Geliştirilen tahmin modelinin güvenilirliği açısından, eğitim ve doğrulama veri kümeleri birbirinden bağımsız olarak kullanılmış; böylece aşırı uyum (overfitting) riskinin önüne geçilerek modelin genelleme kapasitesi değerlendirilmiştir. Bu kapsamda, modelleme sürecinde MATLAB ortamında yer alan Rastgele Orman (Random Forest) kütüphanesi kullanılmış ve tahmin doğruluğunu artırmak amacıyla sistematik bir parametre optimizasyon çalışması yürütülmüştür.

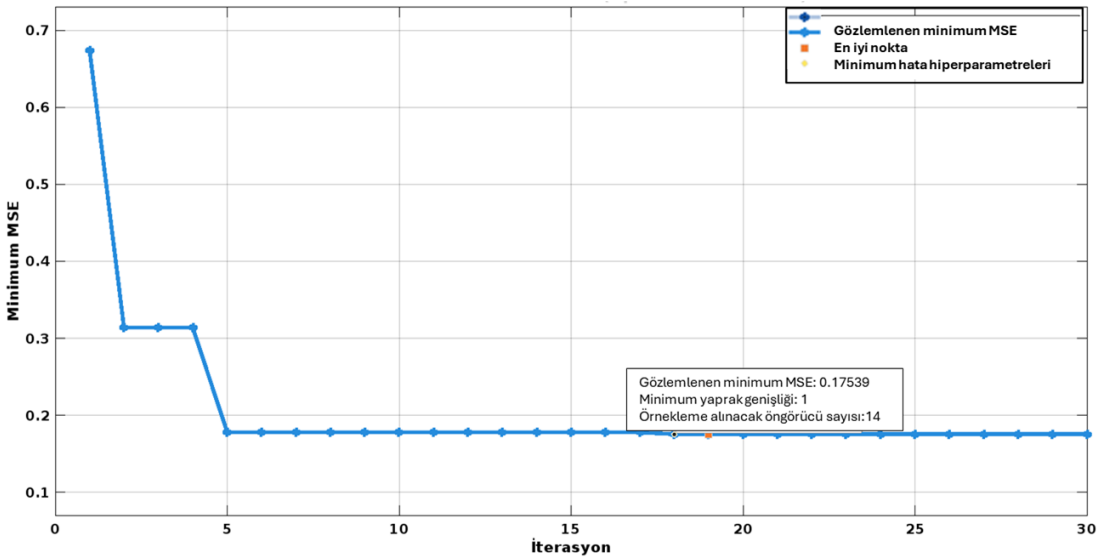
Optimizasyon sürecinde, tahmin hatasını temsil eden ortalama kare hatası (Mean Squared Error - MSE) metriği esas alınmış ve en düşük hata değeri hedeflenmiştir. Yapılan yakınsama analizleri sonucunda, modelin en iyi sonucu verdiği parametre kombinasyonu; minimum yaprak genişliği = 1, öngörücü (predictor) sayısı = 14 olarak belirlenmiştir. Bu parametrelerle oluşturulan modelin istikrarlı biçimde yakınsadığı ve öğrenme sürecinde kararlı hale geldiği Şekil 4.7'de sunulan grafikle görsel olarak da doğrulanmıştır.

Modelin eğitildiği veri kümesi, 22 kanallı örnekten oluşmaktadır. Bu kanallar, iç mekân gürültüsünü etkileyen farklı kaynaklardan toplanan toplam 14 girdi değişkeni ve 1 hedef değişkeni içermektedir. Girdi değişkenleri; motor, egzoz, süspansiyon, lastikler ve hava emiş sistemine ait mikrofon ve ivmeölçer verilerinden oluşmuştur. Hedef değişken olarak ise sürücü koltuğu hizasında ölçülen iç mekân gürültü seviyesi esas alınmıştır.

Rastgele Orman algoritması, karar kurallarını ağaç yapısı içinde temsil ederek hem sınıflandırma hem de regresyon görevlerinde başarılı tahminler yapabilen güçlü bir topluluk modelidir. Sahip olduğu yüksek doğruluk kapasitesi ve esnek yapı

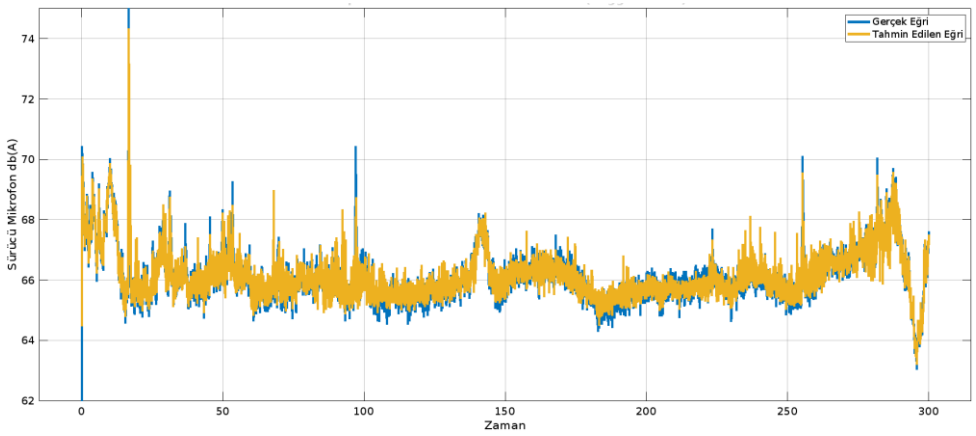
sayesinde, özellikle doğrusal olmayan sistem ilişkilerinin bulunduğu mühendislik problemlerinde geniş bir uygulama alanına sahiptir [32]. Nitekim literatürde, benzer algoritmaların rölanti koşullarındaki gürültü artışları (booming) ve araç titreşimlerinin tahmininde etkin biçimde kullanıldığı çalışmalara da rastlanmaktadır [33].

Bu tez kapsamında geliştirilen model, iç mekân sürücü gürültüsünü tahmin etmeye yönelik olarak yapılandırılmış; modelin eğitiminde kullanılan değişkenler, sistematik olarak belirlenmiş ve doğruluk odaklı şekilde optimize edilmiştir. Parametre ayarlamaları sonucunda, daha yüksek başarımlı tahmin çıktıları elde edilerek modelin doğrulama performansı artırılmıştır.



Şekil 4.7 Rastgele orman grafiği parametre seçimi

Test verilerine karşılık gelen rastgele orman model sonuçları, Şekil 4.8'de gösterilmiştir. Turuncu eğri tahmin edilen eğri iken mavi eğri ise gerçek verileri temsil etmektedir. Genel olarak, tahmin modeli gerçek veriler ile kıyaslandığında %84 doğrulukla tahmin edildiği görülmüştür. Gerçek eğri ve tahmin edilen eğrilerin genliklerinin ve eğri trendlerinin uyuştuğu görülmektedir.



Şekil 4.8 Tahmin edilen eğri ve gerçek eğri

Tablo 4.2'de sunulan istatistiksel değerlendirme sonuçları, geliştirilen makine öğrenimi modelinin araç içi gürültü seviyelerini oldukça yüksek doğrulukla tahmin edebildiğini ortaya koymaktadır. Modelin başarım düzeyini gösteren en önemli parametrelerden biri olan R^2 (R-Squared) değeri, 0.84 olarak elde edilmiştir. Bu sonuç, hedef değişkenin toplam varyansının %84'ünün model tarafından açıklandığını ve dolayısıyla modelin doğrusal olmayan ilişkileri başarıyla öğrenebildiğini göstermektedir.

Modelin tahmin hassasiyetini gösteren RMSE (Root Mean Square Error – Ortalama Karekök Hatası) değeri ise 0.42 olarak hesaplanmıştır. Bu düşük değer, tahmin edilen iç gürültü seviyeleri ile gerçek ölçümler arasındaki farkın minimum düzeyde olduğunu ve tahminlerin istikrarlı bir yapıya sahip olduğunu göstermektedir. Özellikle regresyon tabanlı tahmin problemlerinde, RMSE'nin düşük çıkması, modelin genelleme kabiliyetinin güçlü olduğunu işaret eder.

Ayrıca modelin hata yapısını daha detaylı şekilde değerlendirmek amacıyla hesaplanan diğer iki metrik olan MSE (Mean Squared Error – Ortalama Kare Hatası) ve MAE (Mean Absolute Error – Ortalama Mutlak Hata) değerleri sırasıyla 0.17 ve 0.21 olarak elde edilmiştir. MSE, hataların karesine dayandığı için uç değerlerin etkisini daha belirgin şekilde yansıtırken; MAE, her bir tahmin hatasının mutlak ortalamasını ifade eder. Her iki değerin de düşük çıkması, modelin yalnızca ortalamada değil, uç değerler karşısında da dayanıklı ve tutarlı bir performans sergilediğini göstermektedir.

Genel olarak bu metrikler, önerilen makine öğrenimi tabanlı modelin güvenilir ve öngörülebilir sonuçlar ürettiğini doğrulamaktadır. Ayrıca klasik istatistiksel yöntemlere kıyasla daha kısa sürede ve daha yüksek doğrulukla çalışabilme potansiyeline sahip olduğunu da ortaya koymaktadır. Bu bağlamda, elde edilen sonuçlar, çalışmanın temel hedeflerinden biri olan araç içi GTS karakteristiğinin makine öğrenmesi kullanılarak etkin bir şekilde modellenebileceğini ve bu sayede mühendislik süreçlerine katkı sağlanabileceğini güçlü bir şekilde desteklemektedir.

Tablo 4.2 Tahmin Özet Sonuçları

RMSE	0.42
R-Squared	0.84
MSE	0.17
MAE	0.21

Bu çalışmada Rastgele Orman algoritması yalnızca tahmin yapma amacıyla değil, aynı zamanda hangi girdilerin sonuç üzerinde daha etkili olduğunu anlamak için de kullanıldı. Özellikle hangi değişkenlerin modeli ne ölçüde etkilediğini görmek adına bir önem sıralaması yapılması gerekti.

Bu sıralama için, literatürde sıkça karşılaşılan ve oldukça işe yarar bulunan permütasyon temelli yöntem tercih edildi. Temel fikir şu: Bir değişkenin değerleri karıştırıldığında modelin hata oranı artıyorsa, o değişken önemli demektir. Eğer hata neredeyse hiç değişmiyorsa, demek ki model o değişkene pek de bağımlı değil.

Formülasyonlar kısmında bu yaklaşımın Denklem 4.1 ile matematiksel ifadesi de verilmiştir. Fakat işin özeti, değişkenlerin ne kadar katkı sağladığını test etmek için "ne olursa fark yaratıyor?" sorusuna sistemli bir yanıt aramaktır.

Her bir değişken Xj, modele olan katkısı bakımından değerlendirilir. Bu değerlendirme, ilgili değişkenin değerleri rasgele karıştırıldığında (permütasyon uygulandığında) modelin tahmin hatasında ne kadar artış meydana geldiğine dayanır.

$$\mathrm{VI}_j = \frac{1}{T}\sum_{i=1}^{T}(ERR_t^{perm(j)} - ERR_t^{OOB}) \tag{4.1}$$

Burada:

VI_j: j-inci değişkenin önem değeri

T: Ormandaki toplam ağaç sayısı

ERR_t^{OOB}: t'inci ağaç için orijinal tahmin dışı hata

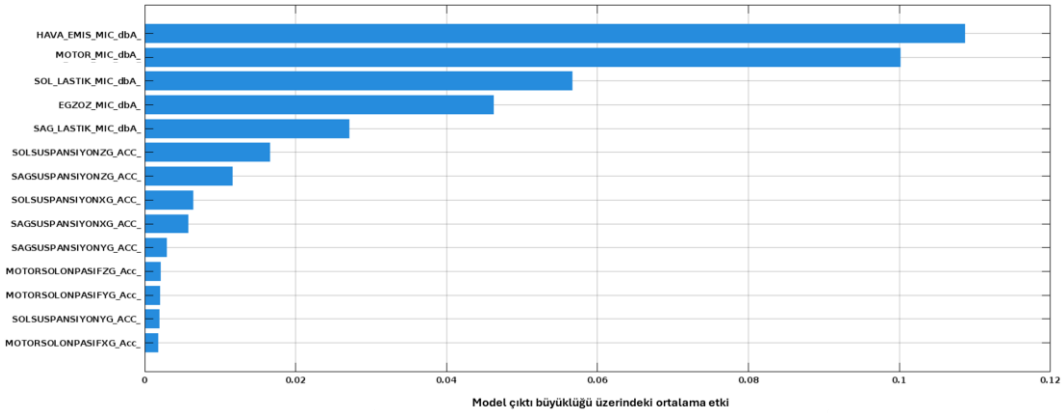
$ERR_t^{perm(j)}$: j'inci değişkenin permütasyonu sonrası oluşan tahmin dışı hata

Eğer Xj değişkeni gerçekten model için önemliyse, o değişkenin değerlerini rastgele karıştırdığımızda tahmin hatasında gözle görülür bir artış meydana gelir. Aradaki fark ne kadar fazlaysa, o değişkenin katkısı da o kadar yüksek kabul edilir. Bu analiz, tüm karar ağaçlarından alınan sonuçların ortalamasıyla yapılır ve böylece genel bir "önem skoru" elde edilir.

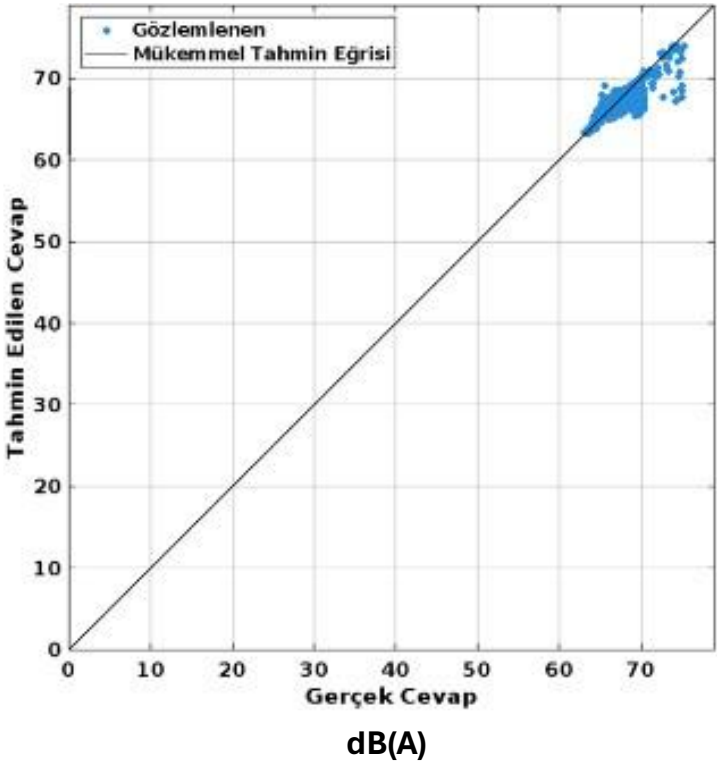
Bu bağlamda Şekil 4.9'da modelin tahmin ettiği değerler ışığında değişkenlerin önem sıralaması görsel olarak sunulmuştur. Özellikle hava emiş ve motor kaynaklı seslerin, 11 Hz frekans bandındaki iç mekân gürültüsü üzerinde baskın bir rol oynadığı ortaya çıkmıştır. Araç testlerinin düşük hızda yapılması ve dizel motorla gerçekleştirilmiş olması göz önünde bulundurulduğunda, bu durum oldukça mantıklıdır; çünkü bu koşullarda motor, egzoz ve hava emiş sistemleri genellikle baskın gürültü kaynakları haline gelir.

Değişken önem sıralaması, sadece tek başına bir sonuç üretmekle kalmamış; aynı zamanda daha önce yapılan korelasyon analizlerinin bulgularını da doğrulamıştır. Bu iki farklı yaklaşım birlikte değerlendirilerek, hangi sistem bileşenlerine öncelik verilmesi gerektiğine dair daha sağlam bir zemin oluşturulmuştur. Araştırmacılar bu tür analizleri karşılaştırarak, iyileştirme yapılacak alanları çok daha güvenli şekilde seçebilir.

Ayrıca model, yalnızca birkaç kaynağa bağlı kalmamıştır. Toplamda beş farklı mikrofonla elde edilen gürültü verileri ve dokuz adet ivmeölçerle elde edilen titreşim verileri kullanılarak yapılandırılmıştır. Bu çoklu veri kaynağı sayesinde, analizler hem daha kapsamlı olmuş hem de tahmin gücü artmıştır. Elbette, bu yöntemin farklı test koşulları altında daha fazla araştırma ile desteklenmesi gerektiğini de unutmamak gerekir.



Şekil 4.9 Model tahmini önem parametreleri

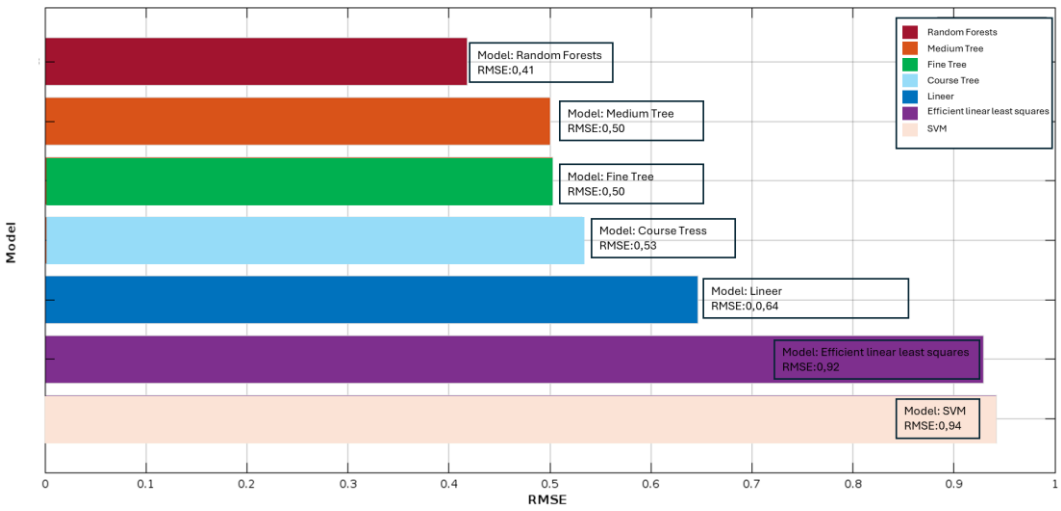


Şekil 4.10 Regresyon uygunluk eğrisi

Şekil 4.10, geliştirilen tahmin modelinin doğruluğunu görsel olarak değerlendirmek amacıyla oluşturulmuş bir regresyon uygunluk grafiğini göstermektedir. Yatay eksende modelin tahmin etmeye çalıştığı gerçek sürücü ses basınç değerleri, düşey eksende ise Rastgele Orman algoritması ile tahmin edilen değerler yer almaktadır. Diyagramda yer alan 45 derecelik eğri, mükemmel tahmin senaryosunu temsil etmektedir; yani tahmin edilen değerlerin birebir olarak gerçek değerlere eşit olduğu durumu göstermektedir.

Grafikte gözlemlenen noktaların büyük çoğunluğunun bu referans eğri etrafında yoğunlaştığı gözlenmektedir. Bu durum, modelin tahmin performansının yüksek olduğunu ve sistematik bir sapma içermediğini göstermektedir. Özellikle değerlerin 60–72 dB(A) bandında yoğunlaştığı ve bu bölgedeki genliklerin doğru şekilde öğrenildiği anlaşılmaktadır. Noktaların düşük yayılım göstermesi, modelin yüksek hassasiyetle çalıştığını ve tahmin sonuçlarının güvenilir olduğunu ortaya koymaktadır. Bu grafik, yalnızca genel eğilimlerin doğru yakalandığını değil, aynı zamanda sayısal olarak tahmin edilen değerlerin de gerçek değerlere çok yakın olduğunu göstermektedir.

Tez kapsamında, araç gürültü, titreşim ve sertlik (GTS) seviyelerini iyileştirmek amacıyla farklı makine öğrenimi algoritmaları değerlendirilmiştir. Yapılan karşılaştırmalar sonucunda, Rastgele Orman algoritmasının doğrusal olmayan verilerde yüksek tahmin doğruluğu sağlayarak en iyi sonucu verdiği belirlenmiştir. Bu algoritma, verilerin önemli özelliklerini doğru bir şekilde analiz etme kabiliyeti sayesinde diğer yöntemlerden ayrılmış ve araç geliştirme süreçlerinde hem zaman hem de maliyet tasarrufu sağlamada önemli bir avantaj sunmuştur. Rastgele Orman'ın özellikle veri gürültüsüne dayanıklı yapısı ve önemli değişkenlerin belirlenmesindeki başarısı, bu çalışmada tercih edilmesinin temel nedenlerindendir.



Şekil 4.5 Makine öğrenimi modellerinin kıyaslanması

Şekil 4.11'de farklı regresyon algoritmalarının tahmin başarımını karşılaştırmak amacıyla Ortalama Kare Kök Hatası (Root Mean Square Error-RMSE) değerleri görselleştirilmiştir. RMSE, tahmin edilen değer ile gerçek değer arasındaki farkın karelerinin ortalamasının karekökü olup, modelin hata oranını

ifade eder; bu nedenle daha düşük RMSE değeri, daha başarılı bir model anlamına gelir.

Grafikte görüldüğü üzere:

- Rastgele Orman algoritması, 0.41 RMSE değeri ile en düşük hataya sahip modeldir. Bu durum, doğrusal olmayan ve çok değişkenli ilişkileri daha başarılı bir şekilde modelleyebildiğini göstermektedir.
- Medium Tree (Orta Karar Ağaç) ve Fine Tree (Detaylı Karar Ağacı) modelleri 0.50 RMSE değeri ile benzer performans sergilemekte, ancak Rastgele Orman algoritması'na göre daha az isabetli tahminler üretmektedir.
- Course Tree 0.53 ve Linear model 0.64 RMSE ile daha yüksek hata oranlarına sahiptir.
- Verimli Doğrusal En Küçük Kareler ve Destek Vektör Makineleri (Efficient Linear Least Squares ve Support Vector Machines -SVM) ise sırasıyla 0.92 ve 0.94 RMSE ile en düşük performansı göstermiştir.

Bu karşılaştırma sonucunda, Rastgele Orman algoritmasının GTS (Gürültü, Titreşim, Sertlik) tahmini uygulamaları için en uygun ve güvenilir model olduğu ortaya konmuştur. Hem düşük hata oranı hem de karmaşık ilişkileri öğrenme yeteneği sayesinde, bu yöntemin klasik modelleme yaklaşımlarına kıyasla üstünlük sağladığı görülmektedir. Bu doğrultuda, GTS analizine uygunluğunun matematiksel temeli önceki bölümlerde detaylı olarak açıklanmıştır.

4.5 Korelasyon Analizi

Tablo 4.3'te gösterildiği gibi, korelogram gösterilerek aynı anda daha fazla bilgi elde edilebilir. Bir korelogram, korelasyon katsayısının bir grafiğidir. Korelasyon katsayısı ne kadar büyükse, değer o kadar koyu olur. Korelasyon katsayısı için Pearson korelasyon katsayısı kullanılmıştır. Hesaplamada kullanılan katsayı denklemi Denklem 4.1'de gösterilmiştir.

$$\rho(X,Y) = \Sigma[(x_i - \bar{x})(y_i - \bar{y})] \,/\, \sqrt{[\Sigma(x_i - \bar{x})^2 \; x \; \Sigma(y_i - \bar{y})^2]} \qquad (4.2)$$

Burada,

ρ: Pearson korelasyon katsayısı

x_i: X değişkenine ait i'nci gözlem değeri

y_i: Y değişkenine ait i'nci gözlem değeri

$\bar{x}$: X değişkeninin ortalaması

$\bar{y}$: Y değişkeninin ortalaması

n: Toplam gözlem sayısı

Bu tez kapsamında, farklı makine öğrenimi algoritmalarının aynı veri kümesi üzerinde çalışırken ortaya koyabileceği model tabanlı varyasyonlar ve yorum farklılıklarını minimize etmek amacıyla, analiz süreci doğrudan sensör kaynaklı ham verilere dayandırılmıştır. Zira her makine öğrenmesi algoritması, veri kümesini kendi matematiksel temellerine göre işlediğinden dolayı, özellikle özellik önemi sıralaması ve değişkenlerin hedef değişken üzerindeki katkı oranlarında farklılıklar meydana gelebilmektedir. Bu tür algoritmik farklar, özellikle doğrusal olmayan sistemlerde daha belirgin hale gelmekte; bazı algoritmaların aşırı öğrenme (overfitting) ya da az öğrenme (underfitting) eğilimlerine girmesi durumunda ise model çıktılarının güvenilirliğini olumsuz yönde etkileyebilmektedir.

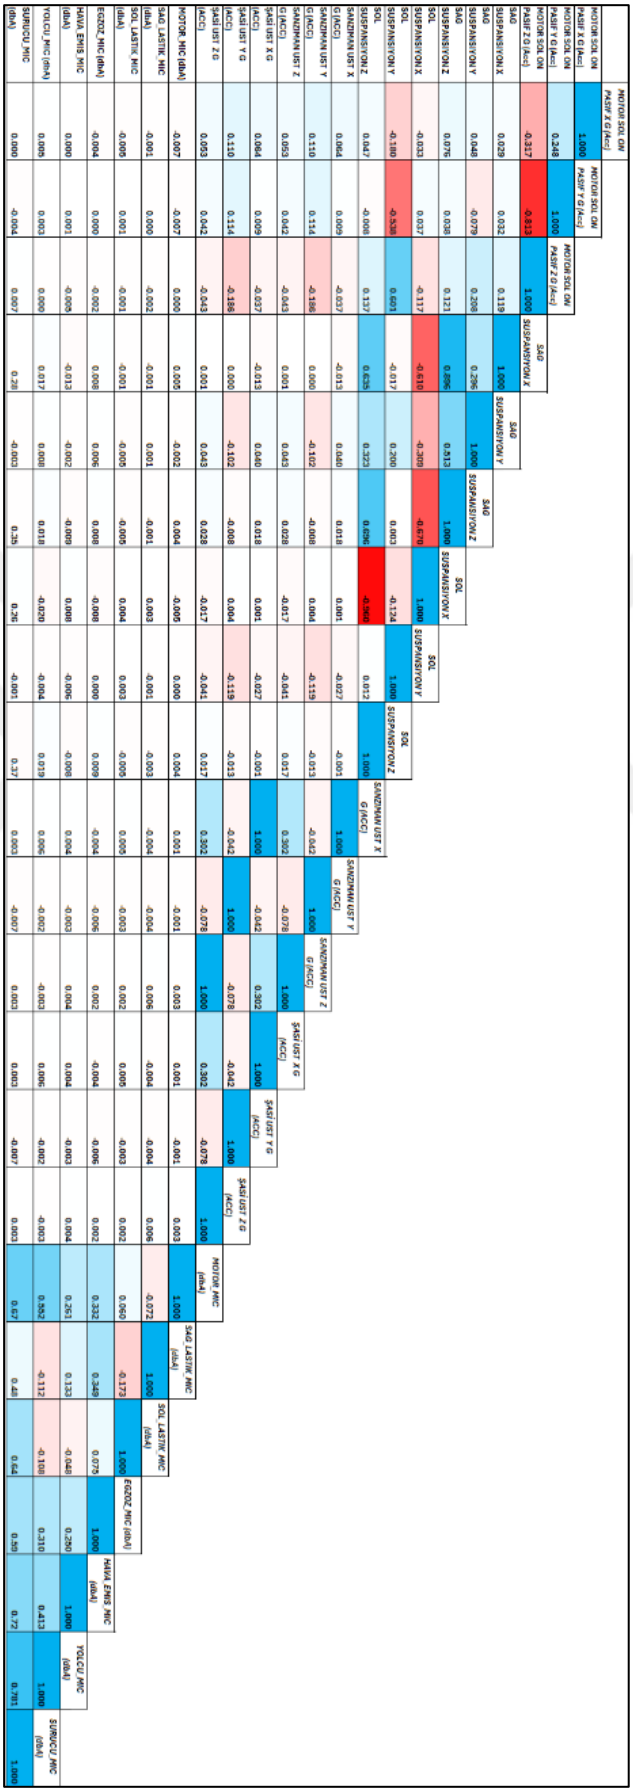
Bu nedenle, çalışmanın bu aşamasında korelasyon analizleri, model sonuçlarından ziyade doğrudan sensör verileri üzerinden gerçekleştirilmiştir. Böylece, her bir uyarım kaynağının hedef sinyal üzerindeki etkisi istatistiksel ve nesnel bir temele oturtulmuştur. Elde edilen korelasyon katsayıları, yalnızca değişkenler arasındaki ilişki gücünü yansıtmakla kalmamış, aynı zamanda duyarlılık analizine temel oluşturmuştur. Bu analiz ile, sistem üzerinde en fazla etkiye sahip olan bileşenler tanımlanmış ve iyileştirme planlamasında öncelikli olarak ele alınmıştır.

Söz konusu yaklaşım sayesinde, model bağımlı belirsizlikler ortadan kaldırılmış; sistemin değerlendirmesi daha tutarlı, açıklanabilir ve tekrar edilebilir hale getirilmiştir. Geliştirme hedefleri, salt model çıktılarından değil, doğrudan gözlemsel verilere dayalı analitik göstergelerden türetilmiş; böylece mühendislik kararları daha sağlam istatistiksel temellere dayandırılmıştır.

Bu kapsamda sunulan Tablo 4.3, 11 Hz frekans bandındaki koltuk gürültüsü ile farklı kaynaklardan elde edilen sinyaller arasındaki korelasyon katsayılarını içermektedir. Katsayılar, en yüksekten en düşüğe doğru sıralanmış ve bu sıralamanın, ilgili değişkenlerin modelleme sürecindeki önem dereceleriyle yüksek

oranda örtüştüğü gözlemlenmiştir. Ayrıca, sistemin hem gürültü hem de titreşim yanıt özelliklerinin farklı dinamiklere sahip olması dikkate alınarak, ilgili kaynaklar ayrı ayrı analiz edilip kategorik biçimde değerlendirilmiştir.

Tablo 4.3 Korelasyon Tablosu



Bu çalışmada yürütülen korelasyon analizleri, 11 Hz frekans bandında iç mekânda algılanan gürültünün başlıca kaynakları üzerinde yoğunlaşmıştır. Elde edilen bulgular, test aracı üzerinde yapılan ölçümler doğrultusunda motor, hava emiş, egzoz ve sol lastik kaynaklarının bu frekans bandındaki iç gürültüye anlamlı düzeyde katkı sağladığını göstermiştir. Özellikle farklı makine öğrenimi algoritmalarının model çıktılarında oluşturabileceği varyasyonların önüne geçmek amacıyla, değerlendirmeler doğrudan sensör verilerine dayalı korelasyon analizleri üzerinden gerçekleştirilmiştir. Bu yaklaşım, veri temelli karar verme sürecini güçlendirmiş ve model bağımsız olarak değişkenler arası ilişkilerin daha nesnel biçimde yorumlanmasına olanak tanımıştır.

Korelasyon analizlerinden elde edilen veriler doğrultusunda gerçekleştirilen hassasiyet analizi, sistem üzerindeki baskın kaynakların belirlenmesini sağlamıştır. Bu doğrultuda geliştirilen iyileştirme hedefleri, yalnızca model çıktıları değil, gözlemsel veri ilişkilerine dayalı olarak şekillendirilmiştir.

4.6 Hassasiyet Analizi

Korelasyon analizleri ile değişkenler arasındaki doğrusal ilişkilerin tespit edilmesinin ardından, her bir uyarım kaynağının hedef sinyal üzerindeki etkisinin istatistiksel olarak değerlendirilmesi mümkün hale gelmiştir. Bu bağlamda, Şekil 4.12'de, 11 Hz frekans bandında yüksek korelasyon gösteren değişkenlerin tüm koltuk bölgesinde ölçülen gürültü seviyesi ile olan doğrusal regresyon ilişkileri sunulmaktadır. Şekilde, X ekseninde analiz edilen uyarım kaynakları (Motor MIC, Sol Lastik MIC, Egzoz MIC, Hava Emiş MIC) yer alırken; Y ekseninde ise araç içi koltuk gürültü seviyesi yer almaktadır. Her bir regresyon doğrusunun eğimi, ilgili kaynağın hedef üzerindeki hassasiyet derecesini temsil etmektedir.

Analiz sonucunda, örneğin Motor MIC verisinin her 1 dB artışı, koltuk bölgesindeki iç gürültü seviyesini istatistiksel olarak ortalama 0.551 dBA artırmaktadır. Benzer biçimde, 11 Hz bandı özelinde değerlendirilen dört değişkenin hassasiyet katsayıları aşağıdaki şekilde hesaplanmıştır:

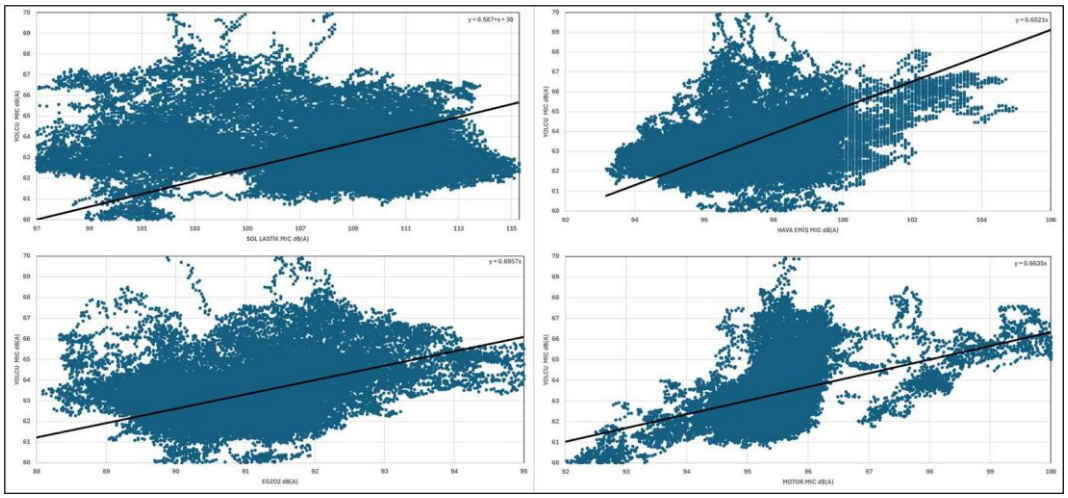
- Motor MIC: 0.551
- Sol Lastik MIC: 0.683
- Egzoz MIC: 0.613

- Hava Emiş MIC: 0.708

Bu sonuçlar, genel olarak yüksek korelasyon gösteren değişkenlerin aynı zamanda hassasiyet analizinde de önemli çıktılar verdiğini göstermektedir. Ancak dikkat çekici bir nokta, korelasyon katsayısı ile hassasiyet katsayılarının tam anlamıyla örtüşmemesidir. Bu durum, iki analiz yöntemi arasındaki temel yaklaşım farklarından kaynaklanmaktadır. Fakat önem sıralamalarının aynı olduğu görülmüştür.

Korelasyon analizi, değişkenler arasındaki doğrusal bağıntıları ölçmeye odaklanırken; hassasiyet analizi, model içindeki değişkenlerin doğrusal olmayan katkılarını, değişkenler arası etkileşimleri ve sistem tepkilerini de içeren çok boyutlu bir yaklaşımla değerlendirir. Dolayısıyla, her iki analiz benzer değişkenleri ön plana çıkarabilse de önem katsayıları arasında farklılıklar gözlenmesi doğaldır. Bu farklılık, özellikle karmaşık ve doğrusal olmayan sistem davranışlarının modellendiği çalışmalarda dikkatle yorumlanmalıdır.

Sonuç olarak, hassasiyet analizleri korelasyona göre daha kapsamlı bir değişken etki değerlendirmesi sunmakta; bu da sistem iyileştirme hedeflerinin belirlenmesinde daha isabetli ve açıklanabilir kararların alınmasına olanak sağlamaktadır. Bu değerlendirmeler, gürültü kaynaklarının hedef frekanstaki etkilerini niteliksel ve niceliksel olarak ortaya koymakta; mühendislik kararları için öncelik sırasının belirlenmesinde doğrudan katkı sunmaktadır.



Şekil 4.6 11 Hz. bandında yüksek korelasyonlu değişkenlere sahip tüm koltuk gürültüsünün doğrusal regresyonu

5
TEKNİK İSTATİSTİKLER KULLANILARAK GELİŞTİRME HEDEFLERİNİN SEÇİMİ

Bu çalışmada, araç içi gürültü seviyesini düşürmeye yönelik geliştirme hedeflerinin belirlenmesi amacıyla, yüksek korelasyona sahip değişkenlerin istatistiksel analizine başvurulmuştur. Bu analizde, tanımlayıcı istatistikler temel alınarak her bir değişkenin dağılımı ve gürültü üzerindeki potansiyel etkisi değerlendirilmiştir. Tanımlayıcı istatistikler, bir veri setinin genel eğilimini ve yayılımını özetlemek için kullanılan yöntemlerdir. Ortalama, medyan, minimum, maksimum, birinci çeyrek (Q1) ve üçüncü çeyrek (Q3) gibi ölçütler bu analiz kapsamında dikkate alınmıştır.

5.1 Analiz Yöntemi

Bu çalışmada, araç içi gürültü seviyesini iyileştirmeye yönelik analizler, belirli bir hedef frekans bandı üzerinde yoğunlaştırılmıştır. Bu kapsamda, 11 Hz frekans bandı için hedef gürültü seviyesi 64 dBA olarak tanımlanmıştır. Analizlerde yalnızca bu değerin çevresindeki ±0.5 dBA aralığında yer alan ölçümler değerlendirmeye alınmıştır. Bu dar veri aralığı seçimi, hedefe yakın verilerin analizde öne çıkmasını sağlayarak istatistiksel değerlendirme sürecinin doğruluğunu ve güvenilirliğini artırmayı amaçlamıştır.

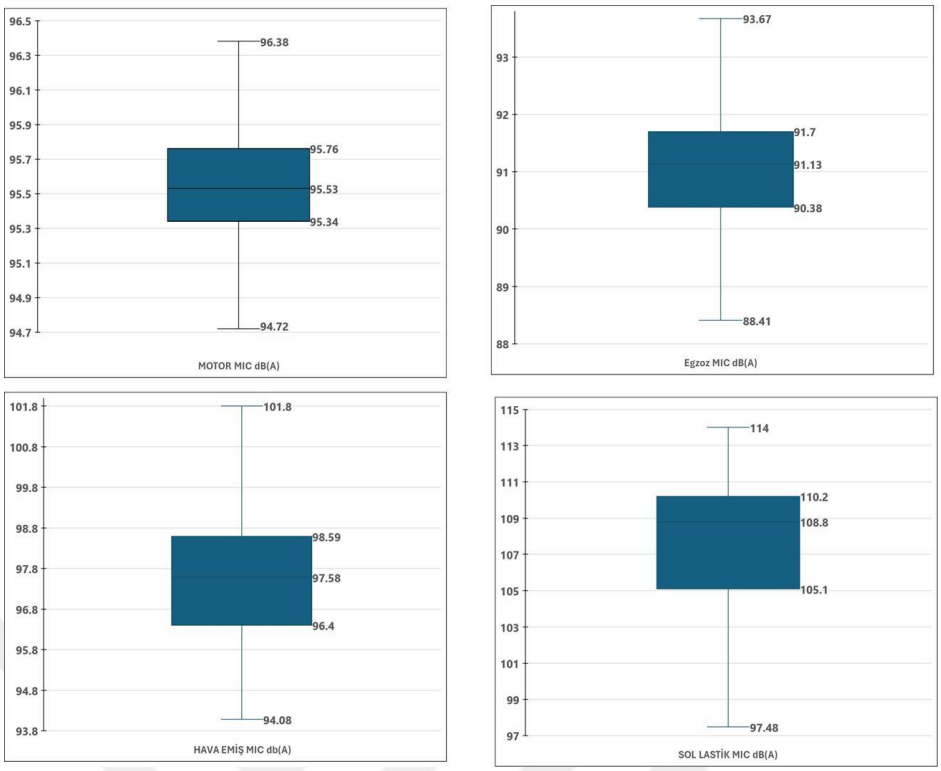
Belirlenen hedef aralığındaki veriler üzerinden yürütülen korelasyon analizleri sonucunda, tüm koltuk gürültüsüyle yüksek doğrusal ilişki gösteren dört ana değişken tespit edilmiştir. Bu değişkenler, geliştirme hedeflerinin hangi seviyelere yönlendirilmesi gerektiğini belirlemek amacıyla tanımlayıcı istatistiksel analiz kapsamında ayrıntılı biçimde incelenmiştir.

İlk aşamada, bu değişkenlere ait medyan ve birinci çeyrek (Q1) değerleri dikkate alınmış; ancak bu istatistiksel ölçütlerin, veri setindeki üst düzey katkı yapan verileri temsil etmede yetersiz kaldığı görülmüştür. Medyan, veri setinin ortanca değerini yansıtırken; Q1 değeri, dağılımın alt %25'lik kısmının üst sınırını belirtmektedir. Bu iki ölçüt, özellikle gürültü seviyesini artıran üst segment verilerin etkisini yansıtmakta yetersiz kalmıştır.

Bu nedenle, üçüncü çeyrek (Q3) değeri esas alınarak geliştirme hedefleri belirlenmiştir. Q3, veri setindeki %75'lik alt kısmın üst sınırını temsil eder ve daha yüksek değerli örneklerin davranışını yansıtır. İyileştirme hedeflerinin agresif ancak uygulanabilir düzeyde oluşturulabilmesi için, bu değerin altında kalan aralıkların hedeflenmesi stratejisi benimsenmiştir. Böylece, yüksek etkiye sahip veri noktalarının sistematik olarak düşürülmesi hedeflenmiştir.

Şekil 5.1'de, bu dört yüksek korelasyonlu değişkene ilişkin kutu grafikler sunulmakta; her grafik, minimum, maksimum, medyan ve çeyrek değerleri açıkça göstererek değişkenlerin dağılım karakteristiğini ortaya koymaktadır. Bu görsel analiz, hangi değişken değerlerinde iyileştirme yapılması gerektiğine dair mühendislik kararlarının alınmasını destekleyici niteliktedir. Ayrıca, her değişkenin çeyrekler arası aralığı (IQR) analiz edilerek, veri yoğunluğunun hangi değer aralıklarında toplandığı ve sapma eğilimlerinin nerede gerçekleştiği istatistiksel olarak belirlenmiştir.

Bu yaklaşım doğrultusunda, geliştirme hedefi olarak Q3 değerlerinin altına inilmesi önerilmiş ve bu değerler, iyileştirme planlaması için hedef sınırlar olarak tanımlanmıştır. Elde edilen istatistiksel bulgular sayesinde, modellemede kullanılan değişkenlerin sınır değerleri daha net biçimde çizilmiş ve hangi kaynakların ne düzeyde azaltılması gerektiği sayısal olarak tanımlanabilir hale gelmiştir. Sonuç olarak, geliştirilen bu yöntem; istatistiksel olarak anlamlı, hedef odaklı ve mühendislik açısından uygulanabilir geliştirme stratejilerinin oluşturulmasına katkı sağlamıştır.



Şekil 5.7 11 Hz bandındaki tüm koltuk gürültüsünün 64 dB(A) için her değişkenlerin geliştirme hedefleri

5.2 Geliştirme Hedefleri

Her bir gürültü kaynağı için Q3 değeri, 11 Hz frekans bandında koltuk içi gürültüsünün 64 dBA altında tutulabilmesi için sınır değer olarak tanımlanmıştır. Tablo 5.1'de bu gürültü kaynaklarına ait hedef değerler verilmiştir.

Tablo 5.3 İyileştirme hedefleri

Değişken	Q3 Değeri (Hedef)	Açıklama
Motor mikrofonu	**95,76 dBA**	**Motor bölgesinden yayılan yapı ve hava kaynaklı ses**
Egzoz mikrofonu	**91,7 dBA**	**Egzoz sisteminden yayılan düşük frekanslı dış ses**
Hava emiş mikrofonu	**98,59 dBA**	**Hava emiş sisteminden gelen emme kaynaklı ses**
Sol lastik mikrofonu	**110,2 dBA**	**Yol ile temas eden sol lastiğin oluşturduğu dış gürültü**

5.3 Gürültü Azaltımı İçin Çözüm Önerileri

5.3.1 Motor Kaynaklı Gürültü

- Motor Takozlarının İyileştirilmesi: Hidrolik motor takozlarının dinamik sertliği optimize edilerek düşük frekanslı yapı kaynaklı yayılım azaltılabilir.
- Krank mili balans optimizasyonu: Düşük sıra frekanslarını azaltmak için balans iyileştirmesi ve ateşleme zamanlaması optimizasyonu yapılabilir.
- Motor kapağı içi akustik izolasyon: Özellikle 11 Hz bandı gibi düşük frekanslar için ses emici viskoelastik katmanlar motor kapağı altına entegre edilebilir.
- Pasif akustik absorbanlar (damping pad): Motor yakınlarında gürültü yansımalarını emen çok katmanlı kaplamalar kullanılabilir (bitüm+köpük kombinasyonları).

5.3.2 Sol Lastik Gürültüsü (Sol Lastik MIC)

- Süspansiyon burçlarının dinamik sertlik ayarı: Yol titreşimlerinin sönümlenmesini iyileştirerek gövdeye iletilen enerji azaltılabilir.
- Lastik deseni ve yapı seçimi: Düşük frekanslı gürültü azaltımı için blok tipi desene sahip lastikler yerine sürekli sırt yüzeyine sahip modeller tercih edilebilir.
- İç lastik köpük sistemleri (ContiSilent™, Pirelli PNCS): İç yüzeye yerleştirilen ses emici malzemelerle düşük frekanslı rezonanslar azaltılabilir.
- Çamurluk içi izolasyon ve yalıtım levhaları: Tekerlek bölgesinde yayılan hava kaynaklı ses, çamurluk içi fiber mat veya sprey köpük ile azaltılabilir.

5.3.3 Egzoz Gürültüsü (Egzoz MIC)

- Susturucu tasarımının optimizasyonu: Helmholtz rezonatörlü veya çok hazneli susturucular ile 11 Hz altındaki titreşim harmoniklerini sönümleyen sistemler kullanılabilir.
- Egzoz askı sistemi revizyonu: Askıların yumuşaklık/sertlik oranı optimize edilerek titreşimli enerji gövdeye ulaşmadan sönümlenir.

- Esnek bağlantı elemanları (flex joint): Motor ve egzoz arasında esnek boru veya körük kullanarak yapıdan yayılan titreşim azaltılabilir.
- Isıl yalıtım + akustik izolasyon kombinasyonu: Egzoz hattı çevresine düşük frekanslı gürültü için ağır katmanlı bariyerler (mass-loaded vinyl) uygulanabilir.

5.3.4 Hava Emiş Gürültüsü

- Rezonatör eklenmesi: Özellikle 11 Hz gibi düşük frekanslarda çalışacak biçimde boyutlandırılmış akustik rezonatörler (ör. Helmholtz) tasarlanabilir.
- Hava filtresi kutusu yapısal iyileştirme: Kutunun gövdeye bağlantı noktaları titreşim yalıtımlı hale getirilerek yapı kaynaklı titreşim aktarımı engellenebilir.
- Daha esnek hortum kullanımı: Sert plastik borular yerine EPDM ya da silikon bazlı esnek hortumlar kullanılarak titreşimli ses aktarımı azaltılabilir.
- Gövdeyle temaslı boru noktalarının izolasyonu: Hava giriş sisteminde borunun gövdeye değdiği noktalarda titreşim sönümleyici fitiller kullanılabilir.

6 SONUÇ

Bu çalışmada, araç içi konforun önemli belirleyicilerinden biri olan gürültü, titreşim ve sertlik (GTS) parametrelerinin iyileştirilmesine yönelik yenilikçi bir analiz yöntemi geliştirilmiş ve uygulanmıştır. Araçtan elde edilen gerçek yol test verileri, makine öğrenimi tabanlı algoritmalar yardımıyla detaylı biçimde incelenmiş; bu süreçte özellikle korelasyon ve hassasiyet analizleri gibi istatistiksel teknikler entegre edilerek sistematik bir değerlendirme yapılmıştır. Çalışmanın odak noktası olan 11 Hz frekans bandındaki iç mekân gürültüsü hem frekans çözümlemeleri hem de değişkenler arası ilişkilerin modellenmesi açısından temel değerlendirme ölçütü olarak ele alınmıştır. 15 dakikadan uzun süren rastgele sürüş senaryoları altında elde edilen çok kanallı gerçek zamanlı veriler hem ölçüm güvenliği hem de sistem tepkilerinin kapsamlı şekilde gözlemlenmesi adına kritik önem taşımıştır.

Elde edilen bulgular, özellikle Rastgele Orman (Random Forest) algoritmasının doğrusal olmayan veri yapılarında yüksek performans sergilediğini ortaya koymuştur. Bu yöntem, geleneksel analiz araçları olan Transfer Patika Analizi (TPA) ve Operasyonel Deplasman Şekli (ODS) yaklaşımlarına kıyasla çok daha kısa sürede, daha az test verisiyle anlamlı sonuçlar üretebilme kabiliyeti göstermiştir. Bu durum, araç geliştirme döngülerinin süresini kısaltmakta ve test maliyetlerini azaltmakta önemli bir potansiyel barındırmaktadır. Nitekim, klasik TPA süreciyle karşılaştırıldığında, önerilen modelin test ve analiz süresinde kayda değer bir verimlilik sağladığı gözlemlenmiştir. Yaklaşık 2–3 günü bulan geleneksel test döngüsü, bu veri odaklı yöntem sayesinde 1–2 saat gibi oldukça kısa bir süreye indirgenebilmiş; böylece hem zaman hem de maliyet açısından anlamlı bir kazanım elde edilmiştir.

Geliştirme hedeflerinin belirlenmesinde, yalnızca model çıktıları değil; doğrudan sensör verilerine dayalı korelasyon analizi sonuçları dikkate alınmış, böylece istatistiksel olarak güvenilir ve mühendislik açısından uygulanabilir stratejiler geliştirilebilmiştir. Bu bütüncül yaklaşım sayesinde hem teknik doğruluk hem de pratik uygulanabilirlik açısından tatmin edici sonuçlara ulaşılmıştır. Ayrıca, önerilen yöntem; verilerin israf edilmeden anlamlandırılmasını sağlamakta, modelleme sürecinde bilgi kaybını minimize etmekte ve araç içi gürültü ve titreşim karakteristiklerinin çok daha kapsamlı şekilde analiz edilmesine olanak tanımaktadır. Bu durum, yalnızca mevcut projeye özel değil, aynı zamanda gelecekteki araç platformlarının NVH geliştirme süreçlerinde de örnek teşkil edecek bir yapı sunmaktadır.

Sonuç olarak, bu tez çalışması, büyük veri teknikleri ile makine öğrenimi algoritmalarının araç geliştirme süreçlerine entegre edilmesinin hem teknik hem ekonomik faydalarını ortaya koymaktadır. Elde edilen yöntemsel kazanımlar, yalnızca akademik bilgi birikimine değil; aynı zamanda endüstriyel ürün geliştirme süreçlerine de doğrudan katkı sağlayabilecek niteliktedir. Gelecekte, bu yaklaşımların farklı araç segmentlerine uygulanarak daha verimli, hızlı ve maliyet etkin çözümler sunması beklenmektedir.

6.1 Veri Temizliği ve Aşırı Öğrenme Kontrolü

Makine öğrenimi ile veri tahmini yapılmadan önce, yol testlerinden toplanan veriler istatistiksel olarak incelenmiş ve analiz sürecinde kullanılan ivme verilerinin olasılık yoğunluk fonksiyonları incelenerek çıkıntı veriler tespit edilmiştir. Bu çıkıntı veriler, ağırlık merkezinden elde edilen ivme verilerinden çıkarılmıştır. Bu ön işlem, modelin aşırı öğrenme (overfitting) yapmasını engellemeye ve model tahmin doğruluğunu arttırmaya yönelik önemli bir adımdır. Özellikle, aşırı öğrenme riskinin ortadan kaldırılması, modelin gerçek dünya verileriyle daha iyi uyum sağlamasını ve daha güvenilir tahminler üretmesini mümkün kılmaktadır.

Ayrıca, zaman alanında toplanan veriler, doğru bir şekilde frekans alanına dönüştürülerek analiz edilmiştir. Bu adım, modelin doğruluğunu artırırken, yalnızca belirli frekans aralıklarında yapılan tahminler yerine daha geniş bir spektrumda analiz yapılmasını sağlamıştır. Bu yöntem, yalnızca teorik olarak değil, pratikte de güvenilir sonuçlar elde edilmesini mümkün kılmıştır.

6.2 Yeni Veri Analizi Yönteminin Güvenilirliği

Bu çalışmada uygulanan veri analizi yöntemi, mevcut geleneksel analiz tekniklerinin yetersiz kaldığı noktaları hedef alarak önemli bir yenilik getirmiştir. Geleneksel analizler, genellikle sadece belirli bileşenler üzerinden yapılan sıralı analizler ve dinamik özelliklerin doğrusal olmayan etkilerini göz ardı eden tekil FRF (Frekans Tepkisi Fonksiyonu) analizine dayanırken, önerilen metodoloji bu sınırlamaları aşmayı başarmıştır. Bu sayede, veriler arasında doğrudan ve dolaylı etkiler de dikkate alınarak daha bütünsel bir analiz yapılabilmiştir.

Önerilen yöntem, çoklu sensör verilerini bütünleştirerek, araçların çeşitli sürüş senaryolarındaki performansını daha kapsamlı bir şekilde incelemiştir. Geleneksel yöntemlerde genellikle tek bir sensörden alınan verilerle sınırlı kalınırken, bu çalışmada birden fazla sensörün verileri eş zamanlı olarak analiz edilmiştir. Bu kapsamlı veri analizi hem modelin doğruluğunu artırmış hem de araç geliştirme sürecinde elde edilen sonuçları daha güvenilir kılmıştır.

6.3 Klasik Yöntemlere Göre Sağlanan Kazanımlar

Klasik yöntemlerle karşılaştırıldığında, önerilen modelin çok belirgin avantajlar sunduğu gözlemlenmiştir. Örneğin, FRF, GTF (Gürültü Transfer Fonksiyonu) ve TPA (Transfer Fonksiyonu Analizi) gibi mevcut yöntemler yalnızca lineer bileşenler üzerinde yoğunlaşarak, araç içindeki gürültü ve titreşimleri yeterince yansıtamamaktadır. Oysa bizim önerdiğimiz model, doğrusal olmayan dinamikleri ve çoklu sensör verilerini kapsamlı bir şekilde analiz ederek daha doğru sonuçlar elde etmiştir. Bu, aracın iç gürültü, titreşim ve sertlik parametrelerinin birbirleriyle olan etkileşimini daha iyi kavrayabilmemizi sağlamıştır.

Özellikle, iç gürültünün motordan gelen gürültüye olan duyarlılığı 0.751 olarak belirlenmiş ve bu bulgu, motorun gürültü seviyesinin 95.53 dB'yi aşmaması gerektiğini ortaya koymuştur. Bu seviyede yapılan analizler, araç içindeki gürültüyü 64 dB (A)'ya düşürmek için gerekli koşulları ve parametreleri açıkça ortaya koymuştur. Klasik yöntemler, genellikle yalnızca belirli bileşenlere odaklanarak bu tür ayrıntılı ilişkilendirmeleri yapamazken, önerilen yöntem bu tür hesaplamaları doğru bir şekilde gerçekleştirmiştir.

6.4 Gelecek Çalışmalar ve Potansiyel Genişleme

Çalışmamızda elde edilen sonuçların doğruluğu, yapılan istatistiksel analizlerle desteklenmiştir. Ancak, önerilen tekniğin doğruluğunun daha da pekiştirilmesi için, aynı deney tüm frekans aralıklarında tekrar edilerek sonuçlar daha geniş veri setleriyle test edilecektir. Bu sayede, modelin doğruluğunun ve genellenebilirliğinin artırılması amaçlanmaktadır.

Gelecekte, bu teknik sadece belirli bir frekans bandında değil, tüm frekans aralıklarında uygulanarak, daha kapsamlı ve doğru tahminler yapılması sağlanacaktır. Ayrıca, farklı araç türleri ve sürüş koşulları üzerinde testler yapılması, modelin genellenebilirliğini ve güvenilirliğini pekiştirecek, bu da daha geniş bir uygulama alanı yaratacaktır. Büyük veri tekniklerinin entegrasyonu ile daha büyük ve karmaşık veri kümeleri üzerinde yapılan analizler, araç geliştirme süreçlerinde önemli zaman ve maliyet tasarrufları sağlayacaktır.

İleride farklı algoritmalarla karşılaştırmalı çalışmalar yapılması planlanmaktadır. Bu çalışmalarda algoritmaların sadece performans metrikleriyle değil, GTS

sistemlerinin fiziksel modelleme uygunluğu bakımından da değerlendirilmesi hedeflenmektedir.

6.5 Sonuçların Endüstriyel Uygulaması

6.5.1 Araç Tasarım Süreçlerine Entegrasyon

- Tasarım İyileştirmeleri
    - Bileşen Bazlı İyileştirme: Elde edilen bulgular, motor yatakları, egzoz sistemleri, süspansiyon burçları gibi belirli bileşenlerde tasarım değişiklikleri için rehber olabilir.
    - Simülasyon Tabanlı Geliştirme: Gürültü ve titreşim ile ilgili veriler, simülasyon modellerine entegre edilerek ürün geliştirme süreçlerinde kullanılabilir. Örneğin:
        - GTS simülasyonlarında modelleme.
- Gürültü ve Titreşim Azaltma Protokolleri
    - Analiz sonuçları, araç içi yalıtım materyallerinin yerleşimi, motor bölmesi tasarımı veya aerodinamik iyileştirmeler gibi fiziksel değişiklikler için kullanılabilir.
    - Yapısal Modifikasyonlar: Araç gövdesindeki titreşim kaynaklarının azaltılması için yapısal değişiklikler önerilebilir.

6.5.2 Fabrika İçi Üretim Süreçlerine Entegrasyon

- Üretim Kontrolü
    - Veriler, üretim sırasında kalite kontrol süreçlerine entegre edilebilir. Örneğin:
        - Motor montajındaki tolerans sapmalarının titreşim üzerindeki etkileri kontrol edilebilir.
        - Montaj süreçlerinde gürültü ve titreşim testleri standart bir kalite kontrol süreci haline getirilebilir.

- Prototip Geliştirme
    - Elde edilen bulgular, prototip araçlarda hızlı geri bildirim döngüsü sağlayarak üretim süresini kısaltabilir.

6.5.3 Son Kullanıcı Odaklı Uygulamalar

- Kullanıcı Konforu Analizleri
    - Model sonuçları, araç içi konforu artırmaya yönelik müşteri geri bildirimleriyle entegre edilebilir.
    - Örneğin, araç kabininde algılanan gürültü seviyeleri ile kullanıcı memnuniyeti arasındaki ilişki analiz edilebilir.
- Marka Farklılaştırması
    - Gürültü ve titreşim seviyelerinin optimizasyonu, markanızın diğer üreticilere kıyasla daha yüksek konfor standartlarına sahip olduğunu gösterebilir.

6.5.4 Maliyet ve Zaman Kazancı

- Prototip Sayısını Azaltma
    - Gürültü ve titreşim tahmin modelleri, fiziksel prototip sayısını azaltabilir. Bu, üretim maliyetlerini düşürür ve zaman kazandırır.
- Test Süresini Kısaltma
    - Geleneksel uzun süreli test süreçleri yerine, makine öğrenimi tabanlı analizler ile kısa süreli testlerle optimize edilmiş sonuçlar elde edilebilir.

KAYNAKÇA

[1] Dong, L.; Sun, D.; Han, G.; Li, X.; Hu, Q.; Shu, L. Velocity-free localization of autonomous driverless vehicles in underground intelligent mines. *IEEE Trans. Veh. Technol.* 2020, *69*, 9292–9303.

[2] Seif, H.G.; Hu, X. Autonomous driving in the iCity—HD maps as a key challenge of the automotive industry. *Engineering* 2016, *2*, 159–162.

[3] Dong, L.J.; Tang, Z.; Li, X.B.; Chen, Y.C.; Xue, J.C. Discrimination of mining microseismic events and blasts using convolutional neural networks and original waveform. *J. Cent. South Univ.* 2020, *27*, 3078–3089.

[4] Kim, S.K.; Park, Y.J.; Lee, S. Voice activity detection based on deep belief networks using likelihood ratio. *J. Cent. South Univ.* 2016, *23*, 145–149.

[5] Aina, L. True 3D, angle resolved, ultrasensitive IR laser sensor for autonomous vehicles. *Infrared Technol. Appl. XLV Int. Soc. Opt.Photonics* 2019, *11002*, 110021G.

[6] Schreurs, M.A.; Steuwer, S.D. Autonomous driving-political, legal, social, and sustainability dimensions. In *Autonomes Fahren*; Springer: Berlin/Heidelberg, Germany, 2015; pp. 151–173.

[7] Sanghani, R.R.; Cherian, T.; Loganathan, S.; Suhalka, K.; Thomas, J. *Tire GTS Optimization for Future Mobility*; SAE Technical Paper 2020-01-1520; SAE International: Warrendale, PA, USA, 2020.

[8] Hussain, R.; Zeadally, S. Autonomous cars: Research results, issues, and future challenges. *IEEE Commun. Surv. Tutor.* 2018, *21*, 1275–1313.

[9] Holehouse, R.; Shahaj, A.; Michon, M.; James, B. Integrated approach to GTS analysis in electric vehicle drivetrains. *J. Eng.* 2019, *2019*, 3842–3847.

[10] Souksavanh, V.; Liu, Y. GTS Data Analytics and Its Application in Vehicle Rating. In Proceedings of the 2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA), Bangkok, Thailand, 16–21 April 2020; pp. 287–292.

[11] Taratorkin, A.I.; Belevich, A.V.; Taratorkin, I.A.; Trusevich, I.A. Strategy for optimizing the GTS parameters of the transport vehicle powertrain during its design. *IOP Conf. Ser. Mater. Sci. Eng.* 2020, *5*, 052085.

[12] Farahani, A.M.; Heshmatnejad, H. Towards Automotive GTS Enhancement: Structural Dynamics Analysis of a Vehicle Wheel. *Am. Sci. Res. J. Eng. Technol. Sci.* 2017, *38*, 51–58.

[13] Qatu, M.S.; King, R.; Shubailat, O.; Wheeler, R. *Determination of Interior GTS Levels from Tire/Wheel Variations Using a Monte Carlo Process*; SAE Technical Paper 2011-01-1580; SAE International: Warrendale, PA, USA, 2011.

[14] Panza, M.A. A review of experimental techniques for GTS analysis on a commercial vehicle. *Energy Procedia* 2015, *82*, 1017–1023.

[15] Knechten, T.; van der Linden, P.J.; Morariu, M.C. Improved FRF acquisition method for vehicle body GTS analysis. *Sound Vib.* 2017, *51*, 8–13.

[16] Sturm, M.; Marchand, C.; Priebe, M.; Sherman, S.; Yankonis, M.; Moorhouse, A.; Hirscher, J.; Parikh, S. Robust GTS development of steering systems using in-situ blocked forces from measurements with low-noise driver simulators. In Proceedings of the INTER-NOISE and NOISE-CON Congress and Conference, Grand Rapids, MI, USA, 10 November 2017; pp. 687–694. *Sensors* 2022, *22*, 2226 18 of 18

[17] Vip, S.A.; Hollmann, J.; Ponick, B. GTS-simulation of salient-pole synchronous machines for traction applications. In Proceedings of the 2019 International Aegean Conference on Electrical Machines and Power Electronics (ACEMP) & 2019 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM), Istanbul, Turkey, 27–29 August 2019; pp. 246–253.

[18] Dowsett, A.; O'Boy, D.J.; Walsh, S.J.; Abolfathi, A.; Fisher, S.A. A study of vehicle and measurement GTS variability. In Proceedings of the ISMA2016-USD2016, Leuven, Belgium, 19–21 September 2016.

[19] Hills, E.; Mace, B.R.; Ferguson, N.S. Acoustic response variability in automotive vehicles. *J. Sound Vib.* 2009, *321*, 286–304.

[20] Song, D.; Hong, S.; Seo, J.; Lee, K.; Song, Y. Correlation Analysis of Noise, Vibration, and Harshness in a Vehicle Using Driving Data Based on Big Data Analysis Technique. Sensors 2022, 22, 2226. https:// doi.org/10.3390/s22062226

[21] Tandoğan, F. O.; Vehicle interior noise source contribution and transfer path analysis (Yüksek Lisans Tezi). [İstanbul Teknik Üniversitesi], [Türkiye] (May 2006).

[22] https://www.mathworks.com/discovery/machine-learning.html

[23] A. Falamarzi, S. Moridpour, M. Nazem, and S. Cheraghi, "Development of random forests regression model to predict track degradation index: melbourne case study," in 12 Journal of Advanced Transportation *Proceedings of the Australasian Transport Research Forum (ATRF), 40th, 2018*, Darwin, Australia, October 2018.

[24] Y. Li, C. Zou, M. Berecibar et al., "Random forest regression for online capacity estimation of lithium

[25] International Organization for Standardization. (2019). ISO 5130: Acoustics – Measurement of sound pressure level emitted by stationary road vehicles. Geneva: ISO.

[26] Song, D.H. Prediction of vehicle interior noise and vibration based on driving data using deep learning. In Proceedings of the Acoustical Society of Korea Conference, Seoul, Korea, 22–27 April 2018

[27] Tukey, J.W. *Exploratory Data Analysis*; Addison-Wesley: Hoboken, NJ, USA, 1977; Volume 2, pp. 131–160.

[28] Dong, W.; Chen, T.; Tiˇno, P.; Yao, X. Scaling up estimation of distribution algorithms for continuous optimization. *IEEE Trans. Evol. Comput.* 2013, *17*, 797–822.

[29] Ahmad, I.; Basheri, M.; Iqbal, M.J.; Rahim, A. Performance comparison of support vector machine, random forest, and extreme learning machine for intrusion detection. *IEEE Access* 2018, *6*, 33789–33795.

[30] Ha, C.Y.; Seo, J.J.; Sim, H.J. A Study on Correlation between Vehicle Vibration and Control Signals using Data mining Technique. In Proceedings of the Korean Society for Noise and Vibration Engineering Conference, Jeju-si, Korea, 20–22 February 2019; p. 168.

[31] G. M. L. Gladwell and G. Zimmermann, "On energy and complementary energy formulations of acoustic and structural vibration problems," *Journal of Sound and Vibration*, vol. 3, no. 3, pp. 233–241, 1966.

[32] S. H. Sung and D. J. Nefske, "A coupled structural-acoustic finite element model for vehicle interior noise analysis," *Journal of Vibration and Acoustics, vol. 106, no. 2, pp. 314– 318, 1984.*

[33] C. Lucas, D. Shahmirzadi, and M. N. Bahrami, "A FEM-based quasi-static neuro-model for acoustic noise in switch reluctance Motors," *Journal of Computational Acoustics*, vol. 12, no. 1, pp. 85–97

[34] Das, K.R.; Imon, A.H.M.R. A brief review of tests for normality. *Am. J. Theor. Appl. Stat.* 2016, *5*, 5–12

[35] Jolliffe, I. T. (2002). *Principal Component Analysis* (2nd ed.). Springer